

Predikce cen drahých kovů využívaných v automobilovém průmyslu

Jakub Horák¹, Filip Hofmann²

¹ *International School of Management Slovakia, Duchnovičovo námestie 1, 080 01 Prešov, Slovak Republic*

² *Institute of Technology and Business in České Budějovice, Okružní 517/10, 370 01 České Budějovice, Czech Republic*

Abstract

The aim of this study was to analyze and predict the prices of precious metals—palladium, platinum, rhodium, and gold—for the period from October 16 to November 27, 2024.

To achieve this goal, historical price data were utilized, and modern machine learning methods, specifically neural networks, were applied in combination with basic statistical analyses. By comparing predicted and actual values, it was possible to assess the accuracy of individual models and identify trends in price fluctuations. The findings showed that neural networks are effective at capturing price trends, particularly for metals with higher stability, such as rhodium. However, for palladium and platinum, the models tended to underestimate growth phases and smooth out extreme fluctuations. The results also highlighted the importance of geopolitical events and economic shocks, which significantly impact the volatility of precious metal markets. These factors were not fully included in the modeling, leading to reduced prediction accuracy in some cases. The contribution of this study lies in providing a comprehensive perspective on the price trends of key precious metals essential for the automotive industry. The findings may prove valuable not only for car manufacturers but also for investors and other stakeholders. A limitation of the research is the lack of deeper integration of macroeconomic and geopolitical variables, which presents an opportunity for further studies in this field.

Keywords: Neural networks, prediction, palladium, platinum, rhodium, gold

Úvod

V posledních letech jsme byli svědky významných změn v globálním automobilovém průmyslu, které velmi ovlivnili nejen výrobce automobilů, ale i širokou společnost a ekonomiku jako celek. Hlavními faktory, které ovlivnily stabilitu a ceny surovin používaných v tomto odvětví, byly pandemie COVID-19 a geopolitické napětí, kde hlavním viníkem byla válka na Ukrajině. Tyto události odhalily zranitelnost dodavatelských řetězců, kdy Manley, Alonso a Nassar (2022) říkají, že automobilový průmysl je nesmírně závislý na složitých a někdy neprůhledných vícevrstvých globálních dodavatelských řetězcích. Velkým problémem je, že drahé kovy, které jsou nesmírně důležité pro automobilový průmysl – palladium, platina, rhodium a zlato, jsou dle Sun et al. (2022) těženy ve velkém převážně v Rusku a Jižní Africe a upozornily na důležitost strategického plánování v oblasti nejen drahých kovů, ale obecně všech surovin.

Podle Hubicki, Zinkowska a Wójcik (2023) patří palladium, platina, rhodium a zlato mezi nejdůležitější drahé kovy v automobilovém průmyslu, kde se využívají hlavně v katalyzátorech, které pomáhají snižovat emise škodlivých látek. V posledních několika letech poptávka po těchto kovech stále strmě stoupá a je to hlavně díky rostoucím nárokům na ekologičtější automobilovou výrobu a tlak na snížení a minimalizaci uhlíkové stopy. Grad et al. (2021) protože neexistují adekvátní alternativy těchto kovů, neustále roste jejich význam pro automobilový průmysl.

Zlato se v automobilovém průmyslu používá především díky svým výjimečným vodivým vlastnostem a odolnosti vůči korozi. Jedním z hlavních využití zlata je pokovování elektrických kontaktů a konektorů. Zlato je vynikajícím vodičem a na rozdíl od jiných materiálů nepodléhá. Dalším důležitým použitím je v airbagových systémech, kde jsou spínací mechanismy vybaveny zlatými kontakty, aby se zajistilo, že v případě potřeby budou airbasy aktivovány bez jakéhokoliv selhání.

Vzhledem k jejich omezené dostupnosti a koncentrované těžbě v několika zemích, jako je Jižní Afrika a Rusko, se ceny těchto kovů stávají důležitou otázkou ekonomické stability. Podle Granados-Fernández et al. (2021) je vzhledem k rostoucí poptávce po automobilech a díky stále přísnějším ekologickým předpisům vzniká ročně značné množství použitých automobilových katalyzátorů, což vede ke zvýšenému zájmu o jejich účinnou recyklaci a znovuzískání vzácných kovů, které obsahují. Jedním z možných řešení by mohl být 3D tisk. Stejného názoru, že 3D by mohl do budoucna být využíván jsou i Nascimento et al. (2022), kteří říkají, že by se mohli využívat kovové zbytky jako surovina pro výrobu prášku, který bude sloužit jako vstup do kovové 3D tiskárny pro generování udržitelných automobilových součástek.

Tyto drahé kovy ovlivňují nejen automobilový průmysl, ale také ostatní drahé kovy, a dokonce i kryptoměny. Například Huynh et al. (2020) zjistili, že když vzroste cena zlata v poměru k platině, tak dochází ke zvýšení návratnosti Bitcoinu.

Na jedné straně pandemie COVID-19, způsobila výrazné zpomalení výroby a narušení dodavatelských řetězců a díky ní došlo k dramatickému poklesu poptávky po automobilech, následně i po surovinách potřebných k jejich výrobě. Následně se však s oživením poptávky v postpandemickém období se ceny drahých kovů opět zvýšily.

Na druhé straně válka na Ukrajině velmi zhoršila a zkomplikovala situaci na trhu, jelikož Rusko je významným producentem těchto drahých kovů. Jejich ceny mohou ovlivnit další sankce a tlaky západního světa na Rusko, díky čemuž může cena drahých kovů stále růst. Dalším důvodem, proč roste cena drahých kovů je podle Xia a Ghahreman (2023) recyklace katalyzátorů, která je v mnoha zemích nízká, a proto dochází ke ztrátě cenných kovů.

Tato práce má za cíl poskytnout cenné informace a analýzy, které mohou být užitečné pro různé zainteresované strany, od výrobců automobilů po investory a běžné občany, jelikož je společnost jako celek ovlivněna vývojem cen drahých kovů, neboť ceny automobilů, a tím i náklady na dopravu a mobilitu, se promítají do životní úrovně obyvatelstva. Vyšší ceny automobilů mohou omezit přístup k mobilitě pro nižší příjmové skupiny, což může mít dalekosáhlé sociální důsledky. Dále, změny v cenách mohou ovlivnit konkurenceschopnost automobilových výrobců, což se následně promítá do pracovních míst a ekonomického růstu.

V posledních letech došlo k významným změnám v automobilovém průmyslu, ovlivněným pandemií COVID-19 a válkou na Ukrajině, což odhalilo zranitelnost dodavatelských řetězců. Poptávka po drahých kovech, jako jsou palladium, platina, rhodium a zlato vzrostla kvůli ekologickým požadavkům a jejich význam pro výrobu automobilových katalyzátorů.

Cílem práce je predikce cen drahých kovů od 16. října 2024, které jsou v současné době nenahraditelné v automobilovém průmyslu, tedy platina, palladium, rhodium a zlato a jejich porovnání se skutečnou hodnotou do 27.11.2024.

VO1: Jak přesná je predikce budoucích cen palladia?

VO2: Jak přesná je predikce budoucích cen platiny?

VO3: Jak přesná je predikce budoucích cen rhodia?

VO4: Jak přesná je predikce budoucích cen zlata?

Výstupem práce bude zjištění o kolik se predikované ceny drahých kovů, které jsou nezbytné pro fungování automobilového průmyslu měnily, tedy cen, které jsou důležité pro výrobce automobilů, pro investory do těchto drahých kovů a běžné občany.

Literární rešerše

Pro mnoho účastníků komoditních trhů je prognóza cen drahých kovů, jako jsou zlato, stříbro a platina, zásadním úkolem. Tyto kovy hrají důležitou roli nejen jako investiční aktiva, ale také v průmyslovém odvětví, zejména v automobilovém průmyslu. Přesná předpověď cen těchto kovů je proto důležitá jak pro investory, tak pro výrobce, kteří musí plánovat náklady na suroviny. Odhad budoucího vývoje však není snadný, protože ceny drahých kovů ovlivňují faktory jako globální ekonomická situace, změny v měnové politice a geopolitické události. Navíc jsou ceny zlata, platiny a zbylých zkoumaných kovů téměř vždy nestacionární, tedy jejich dlouhodobé hodnoty se neustále mění. Tato nestabilita představuje výzvu pro predikci cen a zároveň podtrhuje význam těchto kovů na globálním trhu. Každý účastník k predikci cenových řad přistupuje jinak. Například Xu a Zhang (2024) zkoumali potenciál modelů nelineárních autoregresních neuronových sítí pro předpovídání denních cenových řad platiny a palladia po dobu přibližně padesáti let a ve svém výzkumu zjistili, že výkon modelů z hlediska relativní

střední kvadratické chyby je 1,86 % a 3,61 % pro platinu a paladium. Dále například Raj et al. (2024) predikovali vývoj cen zlata, stříbra a platiny do konce roku 2024 a použitím Nearest Neighbors v softwaru Wolfram Mathematica zjistili, že nejnvýnosnější investiční páry jsou zlato-platina a stříbro-platina a při investování do jednoho kovu zvolili platinu jako nejvhodnější investiční nástroj. Rozdílný názor mají Mamplata, Mamon a David (2022), kteří pomocí rekurzivního modelu říkají, že investice do palladia jsou lepší než investice do zlata, stříbra a platiny.

K předvídání budoucího vývoje těchto cen se využívá řada metod, které umožňují zpracovat složité vztahy mezi tržními faktory a odhadnout, jak se ceny budou vyvíjet. Mezi nejpoužívanější přístupy patří časové řady, kdy modely pomáhají analyzovat sezónní trendy, cykly a nestabilitu v datech. Tyto modely dokáží zohlednit dlouhodobé vzorce chování trhů a změny v cenách způsobené jak ekonomickými podmínkami, tak poptávkou v průmyslových odvětvích. Moderní technologie umožňují také využití strojového učení a neuronových sítí, které dokáží zpracovat velké objemy dat a najít skryté vzory v pohybech cen. Tyto pokročilé algoritmy mohou zvýšit přesnost prognóz tím, že zahrnují složité vztahy mezi tržními proměnnými, které by tradiční metody nemusely zachytit. Kombinace těchto přístupů poskytuje investorům a výrobcům nástroje pro lepší rozhodování a plánování na volatilních trzích s drahými kovy. S tímto tvrzením souhlasí i Varshini, Kayal, a Maiti (2024) kteří pomocí různých modelů strojového a hlubokého učení Stacked Long-Short Term Memory, Convolutional LSTM, Bidirectional LSTM, Support Vector Regressor, Extreme Gradient Boosting a Gated Recurrent Unit zjistili, že hodnoty střední absolutní procentuální chyby ukazují, že různé modely strojového a hlubokého učení dokážou efektivně předpovídat budoucí ceny kovů. Nicméně, výkon jednotlivých modelů se značně liší v závislosti na výběru kovu, délce vzorku a typech vstupních dat.

Ropa bývá často spojená s drahými kovy, protože oba tyto trhy jsou vzájemně propojeny mnoha ekonomickými faktory. Ropa, jakožto klíčová komodita v globální ekonomice, ovlivňuje náklady na dopravu, výrobu i průmyslovou produkci, což má nepřímý vliv na ceny drahých kovů. Jak roste cena ropy, může se měnit poptávka po automobilech nebo alternativních zdrojích energie, což má dopad na poptávku po těchto drahých kovech. Toto tvrzení podporuje výzkum, který provedli Khan, Shahbaz a Napari (2023) kteří díky empirické analýze vyzkoumali, že ceny ropy, zlata a platiny jsou, s výjimkou několika málo případů, trvale nestabilní a vykazují dlouhodobé změny. Ropa a drahé kovy se často sledují společně, protože pohyby na jednom trhu mohou mít přímé nebo nepřímé důsledky na druhý. Například Mohsin a Jamaani (2023) pomocí nové konvoluční neuronové sítě s hlubokým učením zjistili nelineární korelaci mezi volatilitou cen ropy a cenami drahých kovů. Na volatilitu se ve svém výzkumu zaměřili Oláh, Noor a Uddin (2023) kteří použitím standardního prediktivního regresního modelu z týdenních dat realizované volatility došli k zjištění, že platina, paladium, zlato a ropa vykazují značnou předvídatelnost při odhadech realizované volatility během globální finanční krize. Na vliv ropných šoků se podívali Chai et al. (2021) kteří ve svém výzkumu využili STL-ETS (Seasonal and Trend decomposition using Loess – Error, Trend, Seasonality), neuronovou síť a Bayesovský strukturální model časových řad k predikci návratnosti ceny zlata a poukazují na to, že šoky výnosů ropy a indexu

VIX (Volatility index) mají pozitivní vliv na zhodnocení ceny zlata, zatímco šoky spojené s indexem amerického dolaru působí na výnosy zlata negativně.

Drahé kovy jsou ovlivněny i ekonomickou situací ve světě. Například Apanovych et al. (2024) pomocí obsahové analýzy odhalili, že přestože je zájem o zlato obvykle vyšší během období ekonomické nejistoty a inflace, nedostatek hotovosti není klíčovým faktorem, který by výrazně ovlivňoval rozhodnutí zlato prodat. Na to Brabenec et al. (2020) ve svém výzkumu, ve kterém použili neuronové sítě, rozhodovací strom, gradientem zesílený strom, lineární regrese a nejbližší sousedy zjistili, že na počátku ekonomické recese investoři často nakupují zlato, jako způsob, jak ochránit hodnotu svého majetku. Kvůli tomu však mohou brzy čelit nedostatku hotovosti, což je poté nutí zlato znovu prodat. Říkají, že v moment, kdy nastává ekonomická recese klesne cena zlata.

Zlato není pouze ovlivňovanou komoditou, ale jako takové ovlivňuje další věci, jak zjistili například Ali et al. (2022) použitím nové bootstrapové autoregresivní distribuovaného lag testování. Vyzkoumali, že cenové šoky zlata negativně ovlivňují ceny bydlení v Číně, a to jak v krátkodobém, tak i dlouhodobém horizontu.

Uyar, Uyar, a Balkan (2024) využili logistickou regresi, podpůrné vektorové stroje, CART (Classification and Regression Trees), náhodné lesy, extrémní zesílení gradientu a algoritmy neuronových sítí a říkají, že makroekonomické faktory hrají klíčovou roli při vzniku cenových bublin u drahých kovů. Zvláště index spotřebitelské důvěry v USA se ukázal jako společný faktor, který pozitivně ovlivňuje pravděpodobnost bublin ve zlatě, platině a stříbře. Naopak, při vzniku bublin v palladiu se jako hlavní faktory projeví finanční proměnné a proměnné nejistoty.

Co se týká predikce tak Ding a Zhang (2020) použili analýzu časových řad a říkají, že méně likvidní komodity vyžadují zohlednění jak cen, tak i úrovně likvidity z křížových trhů, zatímco u likvidních komodit, jako jsou ropa a kovy, lze předpovědi vytvářet pouze na základě mezi tržních cen.

Existuje několik způsobů sledování změn cen a zjišťování si informací. Velmi populární jsou Google Trends, které poskytují cenný pohled na to, jak se mění zájem veřejnosti o konkrétní aktiva. Miao et al. (2022) použitím lineární Grangerovy kauzality a neparametrické kauzality v kvantilech zjistili, že investoři předtím, než se rozhodnou investovat, často vyhledávají informace online, hlavně na Google Trends, aby získali přehled o možném budoucím vývoji cen. Na podobné téma se zaměřili i Salisu, Ogbonna a Adewuyi (2020) prostřednictvím vysokofrekvenčních dat, zkreslení endogenity v důsledku pravděpodobného vyloučení důležitých prediktorů a persistence v důsledku dynamického chování ekonomických subjektů říkají, že Google Trends pozitivně a významně ovlivňují výnosy zmíněných drahých kovů.

Pro zpracování dat u výzkumných otázek V01 až V04 budou využity neuronové sítě a základní statistické metody a jako metoda sběru dat bude využita obsahová analýza.

Data a metody

Pro získání klíčových dat výzkumu, bude použit mezinárodně uznávaný web investing.com (investing.com, 2024). Tento postup bude stejný pro všechny analyzované drahé kovy, což umožní snadné získávání dat. Jako první krok se otevře webová stránka investing.com a přejde se do sekce „markets“ (trhy), kde se následně rozklikne podsekce „commodities“ (komodity). Zde se naleznou podrobné informace o jednotlivých drahých kovech, jako je zlato, platina, palladium a rhodium. Lze použít i rychlejší přístup, je možné přímo napsat název požadovaného drahého kovu do vyhledávacího pole na stránce.

Tento výzkum je zaměřen na analýzu a porovnání investičních příležitostí v období od 16. října roku 2024 do 27. listopadu 2024. Prvním krokem bude vyhledání konkrétního kovu, například zlata, kde se vybere možnost „Gold Futures“. Po otevření této sekce se klikne na podsekcí „Historical Data“ (historická data), kde je možnost zvolit období pomocí kalendáře – nastaví se tedy 16. října 2014 až 27.11.2024. Po zadání tohoto období se klikne na „Download data“ (stáhnout data), což umožní získat požadovaná historická data ve formátu vhodném pro další analýzu.

Pro následnou práci s daty bude použita aplikace Microsoft Excel. Nejprve se otevře stažený soubor a bude provedeno několik úprav. Prvním krokem je odstranění prvního řádku, který obvykle obsahuje nadbytečné informace nebo záhlaví. Následně se přejde k úpravě textu primárně ve sloupci A, kde se data zobrazují ve formě, která se nedá přímo využít. Bude označen tedy celý sloupec A, přejde se na záložku „Data“ a bude vybrána funkce „Text do sloupců“. V otevřeném dialogovém okně bude zvolen „Oddělovač“ a následně kliknutím na „Další“. Zde se vybere „čárka“ jako oddělovač a do pole „Jiné“ se přidá lomítko (/). Po provedení těchto nastavení bude dokončena úprava kliknutím na „Další“ a poté „Dokončit“.

Následně se odstraní text v buňkách, nechají se pouze čísla, která tvoří datum a jejich hodnoty, které vyjadřují hodnotu kovu k danému datu. Kromě toho bude potřeba zajistit, že formát datumu bude vhodný pro tvorbu grafů. V prázdné buňce se zadá funkce „DATUM“, kde jako rok budou použity hodnoty zadané ve sloupci C, jako měsíc hodnoty ze sloupce A a jako den hodnoty ze sloupce B. Tento vzorec se následně aplikuje na celý sloupec, aby se zajistilo zobrazení datumu pro všechna data v souboru.


Další krok zahrnuje úpravu formátování číselných hodnot ve sloupci obsahujícím ceny kovu. Označí se celý sloupec, přejde se na záložku „Domů“ a vybere se „Najít a vybrat“. Bude zvolena možnost „Nahradiť“ a do pole „Najít“ se napíše čárka, přičemž pole „Nahradiť“ bude ponecháno prázdné. Klikne se na „Nahradiť vše“, čímž se odstraní všechny čárky. Následně do pole „Najít“ bude napsána tečka a do pole „Nahradiť“ vložena čárka, což zajistí správné formátování čísel.

Pro přehlednější je možné vytvořit nový prázdný první sloupec, kam se doplní záhlaví. V horní buňce sloupce s daty se napíše „Datum“ a nad sloupec s cenami kovu „Cena“. Tímto způsobem budou data připravena k další analýze a tvorbě grafů, což umožní snadno identifikovat trendy, které jsou zajímavé k danému tématu.

Pro řešení všech výzkumných otázek budou aplikovány metody umělých neuronových sítí, konkrétně vícevrstvé perceptronové neuronové sítě MLP (Multilayer Perceptrons) a neuronové


sítě s radiální bázovou funkcí RBF (Radial basis function network). Oba typy sítí lze vidět na obrázcích číslo 1 a 2.

Obrázek 1: MLP



Zdroj 1: Keim (2019)

Obrázek 2: RBF



Zdroj 2: He a kol. (2019)

Matematická reprezentace MLP neuronové sítě je vyjádřena vzorcem:

$$y(\vec{x}) = \sigma\left(\sum_{i=0}^n w_i x_i\right)$$

Zatímco RBF neuronová síť je popsána rovnicí:

$$y(\vec{x}) = e - \left(\frac{\|\vec{x} - \vec{c}\|}{b}\right)^2$$

V těchto výrazech \vec{x} představuje vstupy, y je výstup, \vec{c} označuje střed, b je parametr šířky, $\|\vec{x} - \vec{c}\|$ je vzdálenost dle Euklidovské metriky, $\frac{\|\vec{x} - \vec{c}\|}{b}$ odpovídá vnitřnímu potenciálu jednotky RBF a w představuje váhy.

Pro predikci budoucího vývoje bude vybráno pět nejvhodnějších neuronových sítí na základě metody nejmenších čtverců. Časové řady budou rozděleny do trénovací, validační a testovací množiny. Trénovací data (70 % celkového objemu) budou sloužit k učení neuronových sítí, zatímco validační (15 %) a testovací (15 %) data budou určena pro ověření výkonu modelu. Proces tréninku neuronových sítí zahrnuje stanovení počtu neuronů ve skryté vrstvě a optimalizaci váhových parametrů jednotlivých neuronů.

Neuronové sítě budou obsahovat tři vrstvy. Vstupní vrstva bude odpovídat počtu vstupních hodnot představujících denní data od 16. října 2014. Skrytá vrstva bude tvořena neurony, které budou provádět klíčové výpočty na základě tréninkových dat. Výstupní vrstva bude

zodpovědná za generování výsledných predikcí. Pro skrytou a výstupní vrstvu MLP budou využity různé aktivační funkce, konkrétně lineární, logistická, hyperbolický tangens, exponenciální a sinusová. Ostatní parametry sítě budou nastaveny automaticky pomocí nástroje ATS.

Jako chybová funkce bude použita metoda nejmenších čtverců, která je popsána vzorcem:

$$E_{SOS} = \frac{1}{2N} \sum_{i=1}^N (y_i - t_i)^2$$

Zde nám N představuje počet případů použitých při tréninku y_i označuje predikované hodnoty a t_i jsou cílové hodnoty odpovídající těmto případům.

Tato metodologie poskytuje ucelený přístup k predikci budoucího vývoje pomocí pokročilých neuronových sítí.

Výsledky

Tabulka č.1 ukazuje popisnou statistiku historických dat o cenách palladia, která poskytuje přehled o klíčových charakteristikách těchto údajů. Celkový počet záznamů je 2 844, což zajišťuje robustnost analýzy. Průměrná cena palladia v tomto období činila 1 401,336 USD, minimální zaznamenaná cena byla 470,45 zatímco maximální cena dosáhla 3 289 USD, USD což ukazuje na výrazné kolísání hodnot. Směrodatná odchylka je 655,8753.

Tabulka 1: Statistické hodnoty palladia

	Popisná statistika (historická data budoucnosti palladia)				
	Počet údajů	Průměr	Minimum	Maximum	Směr.odchylka
cena	2844	1401,336	470,4500	3289,000	655,8753


Zdroj 3: Investing.com, (2024), vlastní zpracování

V příloze č.1 můžeme vidět přehled aktivních sítí, které se týkají palladia. V prvním sloupečku je uvedeno 5 sítí, které jsou zkoumány. V druhém sloupečku prostřední číslo znamená počet neuronů ve skryté vrstvě. Jedničky jsou vstup a výstup. V dalším sloupečku je popsána trénovací množina. Čím blíže jsou čísla 1čce, tím lépe mají sítě schopnost predikovat. Můžeme v příloze čísla 2 vidět, že se čísla přibližují 1čce, měly by tedy mít velmi dobré prediktivní schopnosti. V příloze číslo 4 jsou čísla nejdál od 1ky co se týká všech zkoumaných hodnot. Dále můžeme vidět uvedené SOS, což znamená suma nejmenších čtverců. Poslední 2 sloupce jsou funkce – hyperbolický tangens a output activation – identická, exponenciální, logistická. Na stejném způsobu jsou postavené i přílohy 4,7 a 10.

Na obrázku č. 1 můžeme vidět časovou řadu zobrazující skutečné a predikované hodnoty. Vodorovná osa X zachycuje pořadová čísla případů (Case number), což odpovídá jednotlivým časovým bodům, zatímco svislá osa Y znázorňuje hodnoty ceny v měrných jednotkách. Modrá čára v grafu reprezentuje skutečné hodnoty ceny. Na počátku časové řady se hodnoty pohybují na nižší úrovni, pod hranicí 1 000, následně dochází k pozvolnému nárůstu ceny, která postupně dosahuje vrcholu kolem hodnoty 3 000. Poté je patrný prudký pokles cen až k jejich nižším úrovním, načež dochází k mírnému oživení a opětovnému růstu ke konci grafu. Barevné čáry v grafu (červená, zelená, fialová a černá) zobrazují predikované hodnoty, které byly odhadnuty.

Tyto predikce ukazují, že modely velmi těsně sledují skutečné hodnoty ceny, což naznačuje vysokou přesnost predikce. Největší rozdíly mezi predikcí a skutečnými hodnotami se objevují v oblastech, kde dochází k prudkým výkyvům cen, zejména v blízkosti maximálních hodnot.

Obrázek 3: Predikovaná cena palladia



Zdroj 4: Vlastní zpracování

V příloze číslo 2 můžeme vidět vývoj ceny palladia v období od 16. října do 27. listopadu 2024. Na počátku sledovaného období cena vykazuje stabilní růst. Od hodnoty 1 034,6 USD dne 16. října postupně stoupá a dosahuje vrcholu 1 234,2 USD dne 28. října. Od 29. října nastává pokles, který je zpočátku pozvolný, ale postupně se zrychluje. Do 4. listopadu cena klesá na 1 081,9 USD, což představuje významný propad o více než 150 USD během necelého týdne. Další fáze vývoje, tedy od 5. do 14. listopadu, se vyznačuje postupným poklesem. Cena klesá z hodnoty 1 089,5 USD na 937,3 USD, což je nejnižší hodnota zaznamenaná v celém sledovaném období. Po dosažení minima dochází růstu, přičemž na konci sledovaného období, dne 27. listopadu, činí 987,1 USD.

Ve třetí příloze jsou výsledky predikce cen provedené neuronovou sítí, která odhaduje hodnoty na základě historických dat. Každý sloupec od 1.cena_(t) do 5.cena_(t) představuje predikci sítí, zatímco poslední sloupec „datum_(t-1)“ označuje datum, od něhož byly predikce počítány. V prvním sloupci (1.cena_(t)) hodnoty zde vykazují pozvolný růst, začínají na 952,5307 USD a končí na hodnotě 957,3130 USD. Tento trend naznačuje mírné zvyšování ceny v krátkodobém horizontu. Naopak druhý sloupec (2.cena_(t)) vykazuje zpočátku mírný pokles, kdy hodnota klesá z 895,4969 USD na 877,4719 USD. Třetí sloupec (3.cena_(t)) ukazuje stabilní růst od 1 000,108 USD po 1 031,740 USD. Čtvrtý sloupec (4.cena_(t)) pokračuje v růstovém trendu, přičemž predikované hodnoty začínají na 1 012,049 USD a stoupají na 1

040,341 USD. Podobně i pátý sloupec (5.cena_(t)) s hodnotami postupně rostoucími z 1 015,445 USD na 1 044,947 USD.

Tabulka č.2 poskytuje přehled základní statistiky historických cen platiny. Celkem bylo analyzováno 3 108 údajů. Průměrná cena platiny v tomto období činila 969,0127 dolarů. Nejnižší zaznamenaná cena byla 595,2 USD, zatímco maximální cena dosáhla 1 318,75 USD. Rozptyl cen, měřený směrodatnou odchylkou 109,3419, ukazuje relativně nižší volatilitu, než je u palladia.

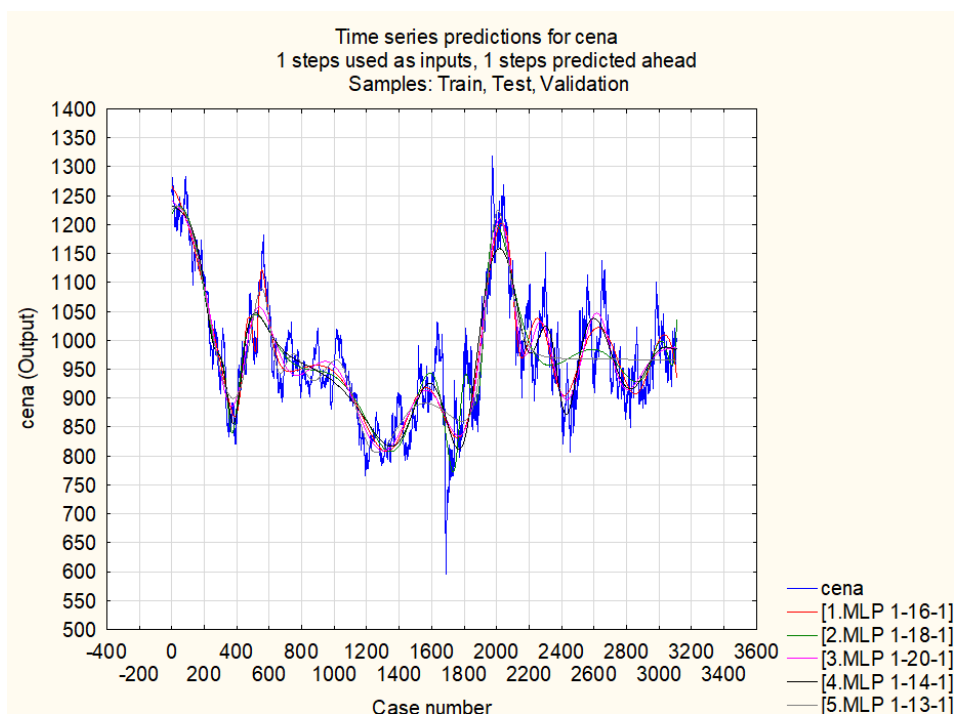
Tabulka 2: Statistické hodnoty platiny

	Popisná statistika (historická data budoucnosti platiny)				
	Počet údajů	Průměr	Minimum	Maximum	Směr.odchylka
cena	3108	969,0127	595,2000	1318,750	109,3419

Zdroj 5: Investing.com, (2024), vlastní zpracování

Modrá čára v obrázku číslo 2 znázorňuje skutečné hodnoty ceny, které vykazují značnou variabilitu v průběhu časové řady. Hodnoty se pohybují mezi minimem okolo 650 USD a maximem zhruba 1 300 USD. Časová řada obsahuje několik výrazných vrcholů a propadů, které odrážejí kolísání ceny v závislosti na čase. Nejvýraznější pokles je patrný kolem případu 1 600, kde cena spadla blízko 650 USD. Naopak, maxima jsou dosažena kolem případu 1 200 a 2 800, kde hodnota překračuje hranici 1 300 USD. Z grafu je patrné, že všechny modely dokážou velmi dobře sledovat skutečné hodnoty ceny, přičemž se přizpůsobují hlavním trendům a výkyvům. V oblastech s prudkými změnami, například kolem minima poblíž případu 1 600, však predikované hodnoty ukazují mírné zpoždění nebo vyhlazení ve srovnání s reálnými daty.

Obrázek 4: Predikovaná cena platiny



Zdroj 6: Vlastní zpracování

V příloze č. 5 můžeme vidět, že cena začíná na hodnotě 997,7 USD dne 16. října a postupně roste na 1 020,1 USD k datu 18. října. Mezi 22. říjnem a 29. říjnem cena zůstává na relativně vysoké úrovni, přičemž dosahuje maxima 1 056,3 USD dne 29. října. Po tomto maximu však dochází k obratu, kdy cena začíná postupně klesat. Dne 31. října klesá na 999,6 USD, což představuje návrat pod hranici 1 000 USD. V listopadu dochází k dalšímu poklesu a následně dosahuje svého minima 943,5 USD dne 13. listopadu. V druhé polovině listopadu se situace mírně stabilizuje. Konec sledovaného období však opět přináší pokles, kdy cena klesá na 924,8 USD k 26. listopadu a končí na 931,8 USD dne 27. listopadu.

Příloha č. 6 zobrazuje výsledky predikce cen platiny na základě historických dat. První sloupec (1.cena_(t)) vykazuje postupný pokles od 934,7039 USD na začátku predikce k 835,5894 USD na jejím konci. Druhý sloupec (2.cena_(t)) naproti tomu ukazuje opačný trend – výrazný růst od 1 039,987 USD na začátku až po 1 287,793 USD na konci. Tento vzestupný pohyb naznačuje, že predikce v delším časovém horizontu očekává růst hodnoty platiny. Třetí sloupec (3.cena_(t)) ukazuje výraznou stabilitu predikovaných hodnot, které se pohybují kolem 986,4 USD s minimálními odchylkami. Tato stabilita naznačuje, že model předpokládá vyvážený trh bez výrazných výkyvů v tomto časovém kroku. Podobně čtvrtý sloupec (4.cena_(t)) vykazuje mírně rostoucí trend od 985,078 USD na začátku k 1 005,104 USD na konci. Pátý sloupec (5.cena_(t)) představuje podobný případ jako třetí neuronová síť, kdy hodnoty vykazují 964 USD.

Tabulka č.3 představuje základní statistický přehled historických cen rhodia. Průměrná cena za sledované období byla 565,9007 USD. Nejnižší zaznamenaná cena byla 60,5 USD, zatímco maximální cena dosáhla 2 535,5 USD, což naznačuje extrémní rozdíl mezi minimálními a maximálními hodnotami. Směrodatná odchylka 573,6039 USD dále poukazuje na vysokou volatilitu trhu s rhodiem.

Tabulka 3: Statistické hodnoty rhodia

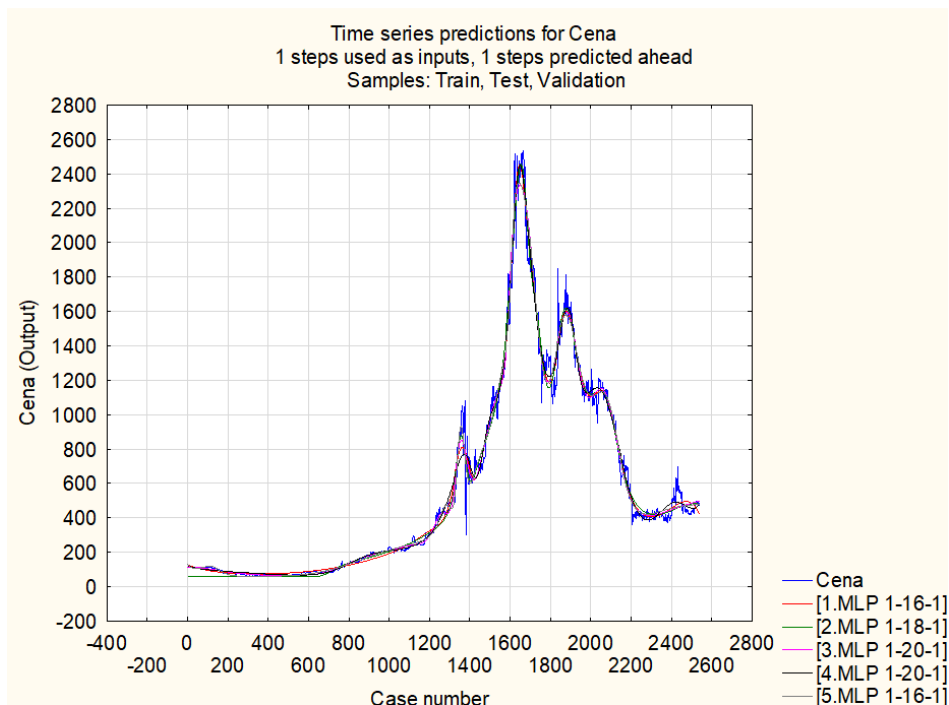
	Popisná statistika (historická data budoucnosti rhodia)				
	Počet údajů	Průměr	Minimum	Maximum	Směr.odchylka
cena	2537	565,9007	60,50000	2535,500	573,6039

Zdroj 7: Investing.com, (2024), vlastní zpracování

Graf na obrázku číslo 3 zachycuje vývoj ceny rhodia. Ceny začínají na nízkých úrovních, pohybujících se mezi 0 a 200 USD, přičemž první fáze dat, do přibližně případu 1 000, ukazuje relativně stabilní období s minimálními výkyvy. Následně, kolem bodu 1 200, dochází k prudkému nárůstu cen, který eskaluje do ostrého růstu, až cena překonává hranici 2 600 USD. Tento vrchol představuje nejvyšší hodnotu v rámci časové řady. Po dosažení maxima dochází k dramatickému propadu cen, kdy hodnota rhodia během relativně krátkého období klesá z 2 600 USD zpět pod hranici 1 000. Predikované hodnoty (barevné čáry: červená, zelená, fialová, růžová a černá) kopírují skutečný vývoj cen s velmi vysokou přesností. Podobně je tomu i při poklesu cen po dosažení vrcholu – modely efektivně predikují hlavní trajektorii, i když některé z predikovaných hodnot mírně zaostávají za skutečnými změnami, zejména v obdobích rychlého poklesu. V závěrečné části grafu, přibližně od bodu 2 400, je vidět stabilizace cen.

Hodnoty se pohybují v rozmezí 400 až 600 USD, přičemž predikované čáry opět přesně sledují skutečné ceny.

Obrázek 5: Predikovaná cena rhodia



Zdroj 8: Vlastní zpracování

Z přílohy č. 8 můžeme pozorovat, že cena začíná na hodnotě 469,5 USD, ale následující den hned klesá na 465 USD. Nejvyšší hodnota sledovaného období je zaznamenána 21. a 22. října, kdy cena dosahuje 493,33. Po tomto vrcholu dochází 23. října k prudkému poklesu na 458 USD. Od 28. října do 30. října se cena stabilizuje kolem 482,5 USD. Listopad přináší další významné výkyvy. Dne 31. října dochází k poklesu na 460 USD, přičemž cena dále kolísá. Nejnižší hodnota 430 USD je dosažena 25. listopadu, což představuje výrazný sestup oproti hodnotám z října. Konec sledovaného období ukazuje mírné zotavení, kdy cena stoupá na 445 USD k 27. listopadu.

V příloze č.9 první sloupec (1.cena_(t)) ukazuje trvalý pokles predikovaných hodnot. Cena začíná na 421,4990 USD na začátku sledovaného období a končí na 307,8024 USD na jeho konci. Druhý sloupec (2.cena_(t)) rovněž ukazuje sestupný trend, přičemž hodnota klesá z 480,8440 USD na začátku na 469,9219 USD na konci sledovaného období. Třetí sloupec (3.cena_(t)) ukazuje odlišný závěr, kdy predikované hodnoty začínají na 496,6637 USD a postupně rostou na 503,8980 USD. Čtvrtý sloupec (4.cena_(t)) vykazuje výrazný růst. Lze vidět, že hodnoty začínají na částce 478,0695 USD a dosahují 555,6600 USD na konci sledovaného období. Pátý sloupec (5.cena_(t)) zobrazuje stabilní, mírně rostoucí trend. Hodnoty začínají na úrovni 478,8847 USD a končí na hodnotě 480,7153 USD.

Zlato

V tabulce č. 4 můžeme vidět 2 565 záznamů. Průměrná cena zlata během sledovaného období činila 1 580,149 USD. Nejnižší cena byla zaznamenána na úrovni 1 049,6 USD, zatímco

nejvyšší hodnota dosáhla 2 691,3 USD, což ukazuje na značné rozpětí cen. Směrodatná odchylka ve výši 368,9390 USD naznačuje mírnou cenovou volatilitu.


Tabulka 4: Statistické hodnoty zlata

	Popisná statistika (historická data budoucnosti zlata)				
	Počet údajů	Průměr	Minimum	Maximum	Směr.odchylka
cena	2565	1580,149	1049,600	2691,300	368,9390

Zdroj 9: Investing.com, (2024), vlastní zpracování

Na začátku časové řady se v obrázku č.4 cena pohybuje kolem 1 100 USD s mírnými fluktuacemi. Do bodu cca kolem 800 záznamu zůstává cena relativně stabilní a kolísá v úzkém rozmezí 1 100–1 300 USD. V této fázi sítě velmi přesně sledují skutečné hodnoty. Mezi body 800 a 1 400 dochází k růstu ceny, která dosahuje přibližně 1 800 USD. Tento nárůst není lineární, protože je doprovázen krátkodobými výkyvy. V některých případech neuronové sítě mírně podhodnocují vrcholy. Po bodu 1 400 dochází k mírnému zpomalení růstu, kdy cena zůstává v rozmezí 1 600–1 800 USD až do bodu 2 000. V této fázi graf ukazuje větší výkyvy cen, kdy některé hodnoty překračují hranici 2 000 USD, zatímco jiné klesají zpět k 1 700 USD. Poté můžeme vidět další růst. Cena začíná rychle stoupat a přibližuje se k hodnotě 2 700 USD a sítě nadále sledují skutečné hodnoty, a to i při prudkém nárůstu ceny. V závěrečné části grafu ceny dosahují téměř 2 900 USD. Sítě zůstávají konzistentní a dobře zachycují trend rostoucí ceny.

Obrázek 6: Predikovaná cena zlata



Zdroj 10: Vlastní zpracování

V příloze číslo 11 kde jsou uvedeny hodnoty zlata, tak na začátku sledovaného období cena zlata činí 2 714,9 USD a postupně roste na 2 754,3 USD k 18. říjnu. Tento růst naznačuje pozitivní tržní sentiment, který pokračuje až do 22. října, kdy cena dosahuje hodnoty 2 784,4

USD. Tento růstový trend naznačuje zvýšenou poptávku nebo jiné pozitivní tržní faktory, které přispěly k zvyšování hodnoty aktiva. K dosažení maxima dochází 30.10.2024. V polovině listopadu dochází k významnému poklesu, kdy cena klesá na minimum 2 593,6 USD. Následující dny však přinášejí oživení, kdy dne 22.11. cena postupně roste na 2 724,9 USD. Závěr sledovaného období přináší opět mírný pokles.

Ve 12. příloze nám první sloupec (1.cena_(t)) ukazuje postupný růst predikovaných hodnot, které začínají na 2 668,696 USD a končí na 2 782,218 USD. Druhý sloupec (2.cena_(t)) rovněž vykazuje růstový trend. Hodnoty se zvyšují z 2 634,163 USD na 2 681,664 USD. Třetí sloupec (3.cena_(t)) ukazuje stabilitu, přičemž lze vidět, že hodnoty rostou pomalejším tempem z 2 605,378 USD na 2 644,767 USD. Čtvrtý sloupec (4.cena_(t)) vykazuje pozvolný, ale zřetelný růst, kdy hodnoty začínají na 2 662,131 USD a dosahují 2 759,413 USD. Pátý sloupec (5.cena_(t)) ukazuje minimální výkyvy, přičemž hodnoty se pohybují mezi 2 688,072 USD a 2 691,300 USD.

Diskuse výsledků

The VOI: Jak přesná je predikce budoucích cen palladia?

Porovnání skutečných cen palladia s jednotlivými sloupci predikcí neuronové sítě ukazuje různé úrovně přesnosti v závislosti na modelovaných hodnotách a schopnosti zachytit reálný vývoj trhu. Skutečné ceny během sledovaného období (16. října až 27. listopadu 2024) vykazovaly výraznou volatilitu, zatímco predikce neuronové sítě měly tendenci k vyhlazování extrémů. Nicméně už u první sítě vidíme významné rozdíly. Například 16. října byla skutečná cena 1 034,6 USD, zatímco model predikoval 952,5307 USD, což je podhodnocení o více než 80 USD. Podobně 24. října, kdy cena vzrostla na 1 172,1 USD, model předpověděl pouze 953,1551 USD, což ukazuje na výrazné podhodnocení v růstovém období. Naopak během poklesů, například 12. listopadu, kdy skutečná cena činila 952,5 USD, byla predikovaná hodnota 952,6011 USD velmi blízká realitě. To naznačuje, že model lépe zachytává klesající trendy než růstové špičky.

Druhý sloupec predikcí přináší podobné výsledky jako první, ale rozdíly mezi skutečnými a predikovanými hodnotami se mohou v některých obdobích prohloubit. Například 22. října, kdy skutečná cena dosáhla 1 090,4 USD, byla predikovaná hodnota 891,8946 USD, což znamená podhodnocení o téměř 200 USD. Tento rozdíl naznačuje, že model nedokázal efektivně reagovat na růstové špičky, což může být způsobeno jeho snahou o vyhlazení extrémů. Během poklesů naopak model vykazuje vyšší přesnost. Například 14. listopadu, kdy skutečná cena činila 937,3 USD, byla predikovaná hodnota 882,8196 USD, což je rozdíl menší než 6 %. Tato tendence naznačuje, že model má lepší schopnost zachytit stabilnější nebo klesající trendy než rychlé a prudké změny směrem vzhůru.

Třetí sloupec přináší ještě stabilnější predikce. Skutečné ceny během růstových fází, například mezi 24. a 28. říjnem, kdy dosáhly vrcholu 1 234,2 USD, byly výrazně vyšší než predikované hodnoty, které se pohybovaly kolem 1 003,798 až 1 009,041 USD. Tento rozdíl potvrzuje, že model nepočítal s tak prudkým růstem a zůstal výrazně podhodnocený. Naopak při poklesech v listopadu, například 18. listopadu, kdy cena činila 1 016,7 USD, byla predikce 1024,985 USD relativně blízká realitě.

Čtvrtý sloupec predikcí ukazuje podobné výsledky jako třetí, přičemž model opět vykazuje podhodnocení během růstových fází. Například 25. října, kdy skutečná cena činila 1 172,1 USD, byla predikce 1 017,107 USD, což představuje podhodnocení o téměř 150 USD. Naopak během listopadových poklesů se predikované hodnoty přibližují skutečným cenám. Například 20. listopadu, kdy skutečná cena činila 1 032,9 USD, byla predikce 1 035,346 USD, což je rozdíl menší než 3 USD. Tento vzorec potvrzuje, že model lépe zachytává stabilní nebo klesající trendy než období výrazné volatility.

Pátý sloupec predikcí například během růstu na konci října, kdy ceny přesahovaly 1 200 USD, model nadále predikoval hodnoty kolem 1 024 USD. Podobně během poklesů ke konci listopadu, kdy skutečné ceny dosahovaly 987,1 USD, model stále předpovídal hodnoty kolem 1 044 USD.

Podrobné porovnání skutečných cen s jednotlivými sloupci predikcí ukazuje, že neuronová síť měla tendenci podhodnocovat růstové fáze a vyhlazovat cenové výkyvy.

Tabulka 5: Rozdíl mezi predikcí sítí a skutečnou cenou palladia

	Síť				
	1	2	3	4	5
Rozdíl o	82,0693	139,1031	34,492	22,551	19,155
	101,5989	159,1578	53,358	41,528	38,037
	111,5954	171,264	60,702	49,31	45,465
	137,4141	197,6124	85,858	74,574	70,647
	120,7306	181,4595	68,512	57,335	53,33
	218,9449	280,2054	166,065	154,993	150,912
	280,6807	344,0762	225,159	214,502	210,148
	278,4843	342,4158	222,305	211,748	207,333
	210,2857	274,7541	153,449	142,991	138,519
	167,9851	232,9912	110,492	100,132	95,606
	127,6613	194,827	67,557	57,571	52,861
	135,1501	202,8579	74,397	64,5	59,753
	96,0368	164,2875	34,636	24,826	20,045
	76,5215	145,3159	14,475	4,75	0,061
	38,7394	109,7172	25,87	35,277	40,174
	2,6863	68,8395	67,931	77,265	82,173
	11,314	60,7605	77,192	86,455	91,371
	18,1437	54,4804	84,652	93,847	98,768
	60,7171	135,5475	8,285	17,237	22,136
	96,4772	171,8613	26,859	17,96	-13,077
76,6354	152,5738	6,404	2,446	7,309	
94,3916	170,8852	23,55	14,747	-9,908	
33,4964	112,2186	39,75	48,404	53,105	
37,9427	117,2239	35,896	44,521	49,177	
29,787	109,6281	44,64	53,241	57,847	
Suma	2645,4895	4294,064	1812,486	1712,711	1640,947

Zdroj 11: Vlastní zpracování

V tabulce můžeme vidět, že nejlepším modelem byla poslední varianta, která přinesla nejmenší rozdíly za celé sledované období.

Výsledky predikce cen palladia vykazovaly odlišné úrovně přesnosti, což souvisí s volatilitou trhu a použitými modely neuronových sítí. Přestože některé predikce dokázaly zachytit obecné trendy, extrémní změny, jako prudké nárůsty a poklesy, byly předpovězeny méně přesně. Tyto závěry korespondují se zjištěními Dinga a Zhanga (2020), kteří tvrdí, že pro méně likvidní komodity, jako je palladium, je nutné do predikce zahrnout i další faktory, například úroveň likvidity a křížové trhy, což nebylo v této práci přímo zohledněno.

Mamplata, Mamon a David (2022), kteří pomocí rekurzivního modelu ve své studii uvedli, že investování do palladia je lepší než investovat do zlata, stříbra a platiny. S tím tato práce nesouhlasí, pokud by se investor řídil predikcemi, protože jediný model z 5 se blížil u palladia k realitě, ale jinak byly výsledky lepší u platiny, rhodia i zlata.

VO2: Jak přesná je predikce budoucích cen platiny?

První sloupec predikcí ukazuje nejnižší hodnoty ze všech sloupců a vykazuje poměrně značné rozdíly od skutečných cen, zejména v období růstu. Například 16. října činila skutečná cena platiny 997,7 USD, zatímco predikovaná hodnota byla pouze 934,7039 USD, což představuje podhodnocení o více než 60 USD. Tento trend pokračuje i v dalších dnech, například 22. října, kdy skutečná cena dosáhla 1 040,4 USD, zatímco model predikoval 923,5157 USD, což znamená odchylku téměř 120 USD. Podobně v období mezi 24. a 28. říjnem, kdy skutečné ceny vzrostly na 1 044,8 USD, predikce zůstaly kolem 911 USD, což naznačuje, že model nedokázal zachytit rychlý růst.

Druhý sloupec predikcí vykazuje vyšší hodnoty než první, což naznačuje, že model v tomto sloupci částečně kompenzuje své podhodnocení. Přesto rozdíly mezi skutečností a predikcemi zůstávají značné, zejména během růstových fází. Například 17. října byla skutečná cena 1 001,2 USD, zatímco predikce činila 1 044,928 USD, což naopak představuje mírné nadhodnocení. Například 29. října byla skutečná cena 1 056,3 USD, ale lze vidět, že predikce činila 1 114,731 USD, což znamená nadhodnocení o více než 50 USD. Nejvyšší rozdíly můžeme vidět v listopadu, kdy skutečné ceny byly pod hodnotou 1000 USD, ale sítě ukazují predikce nad 1200 USD.

Třetí sloupec predikcí ukazuje relativně stabilní hodnoty, pohybující se kolem 986 USD. Tato stabilita se však neprojevuje přesností, zejména v období růstu. Například 18. října, kdy skutečná cena dosáhla 1 020,1 USD, model predikoval 986,4238 USD, což je podhodnocení o více než 30 USD. Podobně 28. října, kdy skutečná cena činila 1 044,8 USD, model predikoval 986,3577 USD, což představuje rozdíl téměř 60 USD. Tato konzervativní tendence modelu je méně užitečná v obdobích vysoké volatility.

Čtvrtý sloupec vykazuje podobný trend jako třetí, přičemž hodnoty se pohybují kolem 985 až 1 005 USD. Například 25. října, kdy skutečná cena činila 1 030,1 USD, model předpověděl hodnotu 986,420 USD, což znamená podhodnocení o téměř 50 USD. Během listopadových poklesů se predikované hodnoty stále pohybují nad skutečnými cenami, například 22. listopadu, kdy skutečná cena činila 966,7 USD a predikce byla 999,771 USD. Tento rozdíl naznačuje, že model zůstává konzervativní i během poklesů, což může snižovat jeho využitelnost při rychlých změnách cen.

V pátém sloupci například 21. října byla skutečná cena 1013,2 USD, zatímco predikovaná hodnota činila 964,8149 USD, což představuje podhodnocení o více než 50 USD. Naopak při poklesech, jako je 25. listopadu, kdy cena dosáhla 940,3 USD, predikce zůstala na 964,5699 USD, což je stále mírné nadhodnocení.

Tabulka 6: Rozdíl mezi predikcí sítí a skutečnou cenou platiny

	Sít'				
	1	2	3	4	5
Rozdíl o	62,9961	42,287	11,2461	12,622	32,8505
	68,2963	43,728	14,7534	15,996	36,3574
	87,7546	52,941	26,7842	27,377	48,3851
	116,8843	31,392	53,9922	54,391	75,592
	103,3403	52,674	38,5004	38,692	60,099
	110,5228	53,383	43,7087	43,68	65,3059
	133,4199	63,476	58,4423	57,385	80,0337
	147,0367	58,431	69,9508	68,598	91,5407
	114,5806	99,574	35,3592	33,694	56,9476
	94,652	128,296	13,2676	11,275	34,8546
	94,5135	164,484	4,2005	0,719	25,7825
	113,0235	155,153	20,4084	16,509	41,9895
	101,4615	175,936	6,5162	2,179	28,0965
	110,1278	176,521	12,8239	8,029	34,4035
	90,2766	233,391	16,7476	23,582	4,8316
	71,4853	261,364	38,041	45,44	16,4614
	69,3228	272,646	42,7348	50,721	21,1544
	72,3891	278,62	42,2288	50,826	20,6474
	113,4447	272,552	11,7082	22,994	9,8808
	120,2565	274,095	7,6039	19,625	13,9878
106,5976	295,91	24,0001	36,784	2,4051	
113,8681	296,577	19,4967	33,071	2,1019	
98,8448	340,708	45,8875	62,905	24,2699	
86,2629	359,793	61,3865	79,339	39,7628	
96,2106	355,993	54,3859	73,304	32,7557	
Suma	2497,5689	4539,925	774,1749	889,737	900,4973

Zdroj 12: Vlastní zpracování

V tabulce číslo 6 můžeme vidět, že nejbližše se přiblížil skutečným hodnotám třetí model.

Predikce cen platiny byla v některých časových obdobích relativně přesná, avšak odchylky byly patrné zejména během prudkých pohybů cen. Uyar, Uyar a Balkan (2024) zdůrazňují, že indexy spotřebitelské důvěry a finanční proměnné mohou výrazně ovlivnit pravděpodobnost bublin v cenách drahých kovů, což by mohlo být příčinou nepřesností v určitých obdobích.

Brabenec et al. (2020) rovněž upozorňují na to, že investoři v období recese nakupují platínu jako bezpečné aktivum, což může způsobit přechodné cenové špičky. Toto nebylo v této práci dostatečně zohledněno, což by mohlo vysvětlovat rozdíly mezi predikovanými a skutečnými hodnotami během volatilních období.

Výsledky oponují studii, kterou provedli Raj et al. (2024) kteří pomocí Nearest Neighbors v softwaru Wolfram Mathematica zvolili platínu jako nejvhodnější investiční nástroj. Predikce

platiny neukázaly tak malé rozdíly oproti rhodiu, takže pokud by investoři věřili těmto predikcím, tak v Rhodiu mají největší šanci uspět.

VO3: Jak přesná je predikce budoucích cen rhodia?

První sloupec predikcí vykazuje nižší hodnoty ve srovnání se skutečnými cenami a výrazné podhodnocení, zejména během růstových fází. Například 16. října činila skutečná cena 469,5 USD, zatímco predikce byla pouze 421,4990 USD, což je rozdíl téměř 48 USD. Tento vzorec pokračuje i v následujících dnech, například 21. října, kdy skutečná cena vzrostla na 493,33 USD, zatímco predikovaná hodnota činila 411,4345 USD, což je rozdíl přes 80 USD. Takové podhodnocení naznačuje, že model nedokáže dostatečně zachytit růstové trendy. Naopak v obdobích poklesu, například 22. listopadu, kdy cena dosáhla 455 USD, byla predikovaná hodnota 328,4860 USD, což ukazuje na významné podhodnocení i v období poklesů.

Druhý sloupec predikcí vykazuje vyšší hodnoty ve srovnání s prvním, ale stále nedokáže zachytit dynamiku trhu. Například 17. října, kdy byla skutečná cena 465 USD, predikovaná hodnota činila 480,6937 USD, což znamená mírné nadhodnocení. Tento trend je patrný i během konce října, například 29. října, kdy skutečná cena byla 482,5 USD, ale predikovaná hodnota činila 478,4801 USD. V listopadu, kdy ceny začaly klesat, se predikované hodnoty postupně vzdalují skutečnosti. Například 25. listopadu, kdy skutečná cena činila 430 USD, byla predikce 470,6597 USD, což ukazuje na neschopnost modelu přizpůsobit se poklesu.

Třetí sloupec ukazuje ještě vyšší hodnoty než druhý, přičemž například 21. října, skutečná cena dosáhla 493,33 USD a model predikoval 497,5784 USD, což je rozdíl velmi malý rozdíl. Nůžky se začínají velmi otevírat v listopadu, kdy 18. listopadu skutečná cena činila 465 USD, zatímco predikce byla 502,4309 USD.

Čtvrtý sloupec ukazuje podobné hodnoty jako třetí, přičemž predikce jsou mírně vyšší než skutečné ceny. Například 24. října, kdy byla skutečná cena 478,7 USD, ale model předpověděl 488,1787 USD, což je rozdíl přibližně 10 USD. Tento rozdíl se zvětšuje v období poklesu, například 27. listopadu, kdy skutečná cena činila 445 USD a predikce byla 555,6600 USD, což znamená nadhodnocení o více než 110 USD.

Pátý sloupec vykazuje nejvíce stabilní hodnoty mezi predikcemi, kdy se hodnoty pohybují mezi 478 až 480 USD. 16. října byla skutečná cena byla 469,5 USD a neuronový model predikoval 478,8847 USD. Nicméně během listopadového poklesu se predikované hodnoty výrazně vzdalují skutečným cenám. Například 21. listopadu, kdy skutečná cena činila 455 USD, byla predikovaná hodnota 480,4907 USD.

Tabulka 7: Rozdíl mezi predikcí sítí a skutečnou cenou rhodia

	Sít'				
	1	2	3	4	5
Rozdíl o	48,001	11,344	27,1637	8,5695	9,3847
	45,4479	15,6937	31,8478	14,2195	13,9359
	81,8955	13,2895	4,2484	9,1877	14,1932
	84,009	13,466	4,4296	7,8753	14,144
	50,8268	21,6822	39,9401	28,8001	21,2349
	73,7091	0,7952	19,4201	9,4787	0,5833
	86,5908	3,8062	16,334	11,5285	3,0269
	88,9509	4,0199	16,511	13,0756	2,9804
	91,0975	3,989	16,9374	14,9068	2,6842
	71,2811	18,0365	39,3632	38,7723	19,6115
	77,3105	21,1648	44,1408	49,6593	23,8708
	79,9935	20,8534	44,2537	51,3879	23,8548
	92,6753	10,5765	34,4061	43,1915	13,8783
	95,3764	10,3142	34,5779	45,05	13,9216
	103,5805	12,2107	38,2595	55,8362	17,0909
	99,4832	18,9212	45,4285	64,871	24,1324
	113,1572	7,8962	34,867	56,2113	13,4435
	120,1431	3,5958	31,0349	54,317	9,4843
	126,7813	8,0693	37,4309	68,8256	15,3742
	134,9814	2,7415	32,5961	66,1092	10,4134
138,7255	1,9082	32,2607	67,9285	9,9522	
126,514	17,0695	47,9248	85,7834	25,4907	
115,119	40,6597	73,5757	120,5589	50,6417	
129,135	29,7935	63,2371	112,5917	40,1786	
137,1976	24,9219	58,898	110,66	35,7153	
Suma	2411,983	336,8186	869,087	1209,396	429,2217

Zdroj 13: Vlastní zpracování

Z dané tabulky lze říct, že tou nejvhodnější možností, se jeví tedy druhý model, který se svojí predikcí nejlépe přiblížil realitě, na rozdíl od zbylých 4 modelů.

VO4: Jak přesná je predikce budoucích cen zlata?

I u prvního sloupce predikcí dochází k výrazným odchylkám. Například 16. října byla skutečná cena 2 714,9 USD, zatímco predikovaná hodnota činila 2 668,696 USD, což je rozdíl přibližně 46 USD. Tento trend podhodnocení pokračuje i v dalších dnech, například 21. října, kdy skutečná cena vzrostla na 2 763,4 USD, zatímco predikce činila pouze 2 681,935 USD. V období klesajících cen v listopadu model vykazuje větší přesnost. Například 14. listopadu, kdy skutečná cena činila 2 596,4 USD, byla predikce 2 746,582 USD, což je rozdíl téměř 150 USD. Model tak spíše odráží celkový trend, ale není schopen přesně zachytit výrazné změny.

Druhý sloupec predikcí ukazuje mírně nižší hodnoty ve srovnání s prvním, což vede k lepší shodě během poklesů, ale k většímu nadhodnocení při růstu. Například 17. října, kdy byla skutečná cena 2 731,4 USD, predikovaná hodnota činila 2 635,642 USD, což představuje podhodnocení o přibližně 96 USD. V období růstu kolem 30. října, kdy skutečná cena dosáhla 2 825,7 USD, predikce činila pouze 2 653,499 USD, což je výrazné podhodnocení o více než 170 USD.

Třetí sloupec predikcí vykazuje nejnižší hodnoty ze všech sloupců, což vede k výraznému podhodnocení během celého sledovaného období. Například 24. října, kdy skutečná cena činila

2 773,3 USD, predikovaná hodnota byla pouze 2 614,249 USD, což je rozdíl přes 150 USD. Tento rozdíl se zvyšuje během období růstu, například 29. října, kdy skutečná cena dosáhla 2 805,8 USD, zatímco predikce činila pouze 2 619,456 USD. Tato konzervativní tendence modelu naznačuje, že je méně citlivý na růstové trendy a spíše se drží stabilních hodnot.

Čtvrtý sloupec predikcí vykazuje vyšší hodnoty než třetí, ale stále výrazně podhodnocuje růstové fáze. Například 17. října, kdy skutečná cena činila 2 731,4 USD, model předpověděl pouze 2 664,452 USD, což je rozdíl přibližně 67 USD. V období poklesu, například 14. listopadu, kdy cena dosáhla 2 596,4 USD, byla predikce 2 729,349 USD, což představuje nadhodnocení o více než 130 USD.

Pátý sloupec vykazuje nejvyšší hodnoty mezi všemi predikcemi a má tendenci nadhodnocovat ceny ve většině období. Například 16. října, kdy skutečná cena činila 2 714,9 USD, predikovaná hodnota činila 2 688,072 USD. Nicméně během poklesu v polovině listopadu, například 25. listopadu, kdy skutečná cena dosáhla 2 630,6 USD, model předpověděl 2 691,300 USD, což je rozdíl téměř 60 USD.

Tabulka 8: Rozdíl mezi predikcí sítí a skutečnou cenou zlata

	Sít'				
	1	2	3	4	5
Rozdíl o	46,204	80,737	109,522	52,769	26,828
	60,063	95,758	124,877	66,948	42,839
	81,465	121,988	152,399	89,664	73,462
	99,806	141,582	172,306	108,343	94,231
	66,545	109,592	140,623	75,423	63,435
	83,38	127,717	159,051	92,604	82,77
	79,888	129,574	162,065	90,527	89,539
	102,508	153,579	186,344	113,509	114,773
	119,724	172,201	205,234	131,091	134,619
	65,337	119,239	152,534	77,073	82,875
	51,458	111,263	145,534	64,704	79,668
	52,456	113,789	148,284	66,087	83,353
	24,448	38,432	73,145	10,429	9,141
	3,044	67,494	102,415	17,455	39,332
	96,712	25,772	9,894	80,706	49,589
	110,833	38,216	2,387	94,421	60,992
	133,556	59,239	23,258	116,735	80,994
	150,182	74,143	38,02	132,949	94,895
	119,309	36,154	0,429	100,404	53,098
	105,646	20,654	16,015	86,317	36,699
	99,385	12,533	24,21	79,629	27,699
	78,627	10,11	46,915	58,442	4,199
	146,114	49,597	12,676	124,19	60,7
	145,065	46,542	9,626	122,701	56,9
117,418	16,864	20,033	94,613	26,5	
Suma	2239,173	1972,769	2237,796	2147,733	1569,13

Zdroj 14: Vlastní zpracování

Nejllepší výsledky nám přinesl poslední model, ale výsledky zlata jsou u všech modelů podobné.

Salisu, Ogbonna a Adewuyi (2020) zdůraznili význam vysokofrekvenčních dat a dynamického chování ekonomických subjektů, což by mohlo zlepšit modely neuronových sítí

použitých v této studii. Tato práce se nicméně držela přístupu založeného na historických cenách, který může být méně přesný v turbulentních obdobích.

Při srovnání s Varshini et al. (2024), kteří použili různé modely hlubokého učení, včetně LSTM a Convolutional LSTM, bylo zjištěno, že výkon modelů se výrazně liší v závislosti na délce časového vzorku a typech vstupních dat. Aplikované modely v této práci zpracovávaly kratší časový úsek, což mohlo přispět k nižší přesnosti během období výrazných změn cen.

Závěr

Závěr práce shrnuje výsledky analýzy a predikce cen drahých kovů využívaných v automobilovém průmyslu – palladia, platiny, rhodia a zlata. Cílem bylo provést predikci cen těchto kovů od 16. října do 27. listopadu 2024 a následně je porovnat se skutečnými hodnotami, což umožnilo identifikovat přesnost zvolených predikčních modelů, tedy neuronových sítí. Cíl práce byl splněn.

Z výsledků je zřejmé, že neuronové sítě se ukázaly jako silný nástroj pro predikci cen, přestože jejich přesnost byla různá v závislosti na analyzovaném kovu. Z výsledků vyplynulo, že neuronové sítě vykazují různé úrovně přesnosti v závislosti na analyzovaném kovu a specifické volatilitě trhu. Nejlepších výsledků bylo dosaženo u rhodia, kde modely dokázaly velmi přesně kopírovat skutečné hodnoty, a to i v obdobích výrazných cenových výkyvů. Například v období od 21. do 25. října 2024, kdy cena rhodia dosáhla svého vrcholu 493,33 USD, se predikované hodnoty pohybovaly velmi blízko této úrovni. Naopak během listopadového poklesu, kdy ceny rhodia klesly pod 450 USD, modely stále zachovávaly relativně vysokou přesnost. Tato schopnost neuronových sítí reflektovat, jak růst, tak pokles cen, ukazuje na jejich vhodnost při práci s volatilnějšími komoditami, jako je právě rhodium.

U palladia a platiny byla situace odlišná. Modely měly tendenci podhodnocovat růstové fáze cen, což bylo zřetelné například na konci října 2024, kdy cena palladia vzrostla na 1 234,2 USD, zatímco predikce se pohybovaly kolem 1 009 USD, což představovalo podhodnocení o více než 200 USD. Během listopadových poklesů však modely u těchto kovů dosahovaly vyšší přesnosti. Například 18. listopadu, kdy skutečná cena palladia činila 1 016,7 USD, byla predikovaná hodnota 1 024,9 USD, což je odchylka méně než 1 %. Tento výsledek naznačuje, že neuronové sítě jsou u těchto kovů schopny lépe predikovat stabilní nebo klesající trendy, ale mají potíže s rychlými růsty cen, které mohou být způsobeny neočekávanými změnami na trhu.

Zlato, které má tradičně nižší volatilitu než ostatní analyzované kovy, tak i přesto vykazovalo ve zkoumaném období nepřesnosti a přenechalo nejlepší predikce právě rhodiu.

Práce rovněž odhalila významné faktory ovlivňující ceny drahých kovů. Geopolitické události, jako válka na Ukrajině, a ekonomické šoky, včetně pandemie COVID-19, měly zásadní dopad na volatilitu trhu. Tato skutečnost podtrhuje potřebu zohlednit širší ekonomické a politické kontexty v budoucích analýzách. Modely použité v této práci ne vždy plně zohlednily tyto externí vlivy, což v některých případech vedlo k méně přesným predikcím.

Práce ukázala, že moderní metody strojového učení, jako jsou neuronové sítě, mají značný potenciál pro analýzu a predikci cen drahých kovů. Současně však zdůraznila jejich omezení, zejména nutnost zahrnutí širších makroekonomických a geopolitických faktorů. Tato zjištění

mají praktické implikace nejen pro automobilový průmysl, který je na těchto kovech vysoce závislý, ale i pro investory, kteří mohou využít přesnějších predikcí pro strategické rozhodování.

Dosažené závěry mají praktické implikace pro automobilový průmysl, investory a další subjekty závislé na vývoji cen drahých kovů. Přesná predikce cen kovů, které jsou klíčové pro výrobu automobilových katalyzátorů a dalších součástek, je nezbytná pro strategické plánování, snižování nákladů a zajištění udržitelnosti produkce. Tato práce prokázala, že moderní metody, jako jsou neuronové sítě, mají značný potenciál přispět k těmto cílům, ale jejich využití vyžaduje důkladné nastavení a zohlednění co nejširšího spektra relevantních faktorů.

Seznam zdrojů

ALI, Mumtaz; SAMOUR, Ahmed; JOOF, Foday a TURSOY, Turgut. Oil prices and gold prices on housing market in China: novel findings from the bootstrap approach. Online. *International Journal of Housing Markets and Analysis*. 2022, roč. 17, č. 3, s. 591-610. ISSN 1753-8270. Dostupné z: <https://doi.org/10.1108/IJHMA-09-2022-0132>. [cit. 2024-10-21].

BRABENEC, Tomas; SULER, Petr; HORAK, Jakub a PETRAS, Milos. Prediction of the Future Development of Gold Price. Online. *Acta Montanistica Slovaca*. 2020, roč. 25. ISSN 1335-1788. Dostupné z: <https://doi.org/10.46544/AMS.v25i2.11>. [cit. 2024-10-21].

DE MATTOS NASCIMENTO, Daniel Luiz; MURY NEPOMUCENO, Renan; CAIADO, Rodrigo Goyannes Gusmão; MAQUEIRA, Juan Manuel; MOYANO-FUENTES, José et al. A sustainable circular 3D printing model for recycling metal scrap in the automotive industry. Online. *Journal of Manufacturing Technology Management*. 2022, roč. 33, č. 5, s. 876-892. ISSN 1741-038X. Dostupné z: <https://doi.org/10.1108/JMTM-10-2021-0391>. [cit. 2024-10-09].

DING, Shusheng a ZHANG, Yongmin. Cross market predictions for commodity prices. Online. *Economic Modelling*. 2020, roč. 91, s. 455-462. ISSN 02649993. Dostupné z: <https://doi.org/10.1016/j.econmod.2020.06.019>. [cit. 2024-10-21].

DUC HUYNH, Toan Luu; BURGGRAF, Tobias a WANG, Mei. Gold, platinum, and expected Bitcoin returns. Online. *Journal of Multinational Financial Management*. 2020, roč. 56. ISSN 1042444X. Dostupné z: <https://doi.org/10.1016/j.mulfin.2020.100628>. [cit. 2024-10-09].

GRAD, Oana; CIOPEC, Mihaela; NEGREA, Adina; DUȚEANU, Narcis; VLASE, Gabriela et al. Precious metals recovery from aqueous solutions using a new adsorbent material. Online. *Scientific Reports*. 2021, roč. 11, č. 1. ISSN 2045-2322. Dostupné z: <https://doi.org/10.1038/s41598-021-81680-z>. [cit. 2024-10-11].

GRANADOS-FERNÁNDEZ, Rafael; MONTIEL, Miguel A.; DÍAZ-ABAD, Sergio; RODRIGO, Manuel A. a LOBATO, Justo. Platinum Recovery Techniques for a Circular Economy. Online. *Catalysts*. 2021, roč. 11, č. 8. ISSN 2073-4344. Dostupné z: <https://doi.org/10.3390/catal11080937>. [cit. 2024-10-11].

HE, Haiqing; YAN, Yeli; CHEN, Ting a CHENG, Penggen. Tree Height Estimation of Forest Plantation in Mountainous Terrain from Bare-Earth Points Using a DoG-Coupled Radial Basis Function Neural Network. Online. *Remote Sensing*. 2019, roč. 11, č. 11. ISSN 2072-4292. Dostupné z: <https://doi.org/10.3390/rs11111271>. [cit. 2024-12-07].

HUBICKI, Zbigniew; ZINKOWSKA, Karolina a WÓJCIK, Grzegorz. A New Impregnated Adsorbent for Noble Metal Ion Sorption. Online. *Molecules*. 2023, roč. 28, č. 16. ISSN 1420-3049. Dostupné z: <https://doi.org/10.3390/molecules28166040>. [cit. 2024-10-09].

CHAI, Jian; ZHAO, Chenyu; HU, Yi a ZHANG, Zhe George. Structural analysis and forecast of gold price returns. Online. *Journal of Management Science and Engineering*. 2021, roč. 6, č. 2, s. 135-145. ISSN 20962320. Dostupné z: <https://doi.org/10.1016/j.jmse.2021.02.011>. [cit. 2024-10-21].

Insights into Gold Investing: Exploring Investor Behavior. Online. *Acta Montanistica Slovaca*. 2024, roč. 28, č. v28/i4, s. 807-818. ISSN 1335-1788. Dostupné z: <https://doi.org/10.46544/AMS.v28i4.02>. [cit. 2024-10-21].

KEIM, R., 2019. How to Train a Multilayer Perceptron Neural Network. All About Circuits [online]. [cit. 2024-12-7]. Dostupné z: <https://www.allaboutcircuits.com/technical-articles/how-to-train-a-multilayer-perceptron-neural-network/>

KHAN, Asad Ul Islam; SHAHBAZ, Muhammad a NAPARI, Ayuba. Subsample stability, change detection and dynamics of oil and metal markets: A recursive approach. Online. *Resources Policy*. 2023, roč. 83. ISSN 03014207. Dostupné z: <https://doi.org/10.1016/j.resourpol.2023.103601>. [cit. 2024-10-21].

MAMPLATA, Jonathan; MAMON, Rogemar a DAVID, Guido. Modelling and filtering for dynamic investment in the precious-metals market. Online. *International Journal of Computer Mathematics*. 2022, roč. 99, č. 12, s. 2382-2409. ISSN 0020-7160. Dostupné z: <https://doi.org/10.1080/00207160.2022.2064192>. [cit. 2024-12-04].

MANLEY, Ross L.; ALONSO, Elisa a NASSAR, Nedal T. Examining industry vulnerability: A focus on mineral commodities used in the automotive and electronics industries. Online. *Resources Policy*. 2022, roč. 78. ISSN 03014207. Dostupné z: <https://doi.org/10.1016/j.resourpol.2022.102894>. [cit. 2024-10-09].

MIAO, Miao; KHASKHELI, Asadullah; RAZA, Syed Ali a YOUSUFI, Sara Qamar. Using internet search keyword data for predictability of precious metals prices: Evidence from non-parametric causality-in-quantiles approach. Online. *Resources Policy*. 2022, roč. 75. ISSN 03014207. Dostupné z: <https://doi.org/10.1016/j.resourpol.2021.102478>. [cit. 2024-10-20].

MOHSIN, Muhammad a JAMAANI, Fouad. A novel deep-learning technique for forecasting oil price volatility using historical prices of five precious metals in context of green financing – A comparison of deep learning, machine learning, and statistical models. Online. *Resources Policy*. 2023, roč. 86. ISSN 03014207. Dostupné z: <https://doi.org/10.1016/j.resourpol.2023.104216>. [cit. 2024-10-20].

OLÁH, Judit; NOOR, Thuhid a UDDIN, Shamim. Realized Volatility Prediction Of The Us Commodity Futures During The Global Financial Crisis (Gfc) And Covid-19 Pandemic. Online. *Polish Journal of Management Studies*. 2023, roč. 27, č. 2, s. 260-277. ISSN 20817452. Dostupné z: <https://doi.org/10.17512/pjms.2023.27.2.16>. [cit. 2024-10-20].

RAJ, Robin Kunju Mol; DLOUHY, Pavel; KOVAC, Vilem; TURINSKÁ, Libuse. Investing in Pairs of Precious Metals: Portfolio Theory Application. Online. *Acta Montanistica Slovaca*. 2024, roč. 28, č. v28/i4, s. 941-951. ISSN 1335-1788. Dostupné z: <https://doi.org/10.46544/AMS.v28i4.12>. [cit. 2024-10-20].

SALISU, Afees A.; OGBONNA, Ahamuefula E. a ADEWUYI, Adeolu. Google trends and the predictability of precious metals. Online. *Resources Policy*. 2020, roč. 65. ISSN 03014207. Dostupné z: <https://doi.org/10.1016/j.resourpol.2019.101542>. [cit. 2024-10-20].

SUN, Shiqiang; JIN, Chenxi; HE, Wenzhi; LI, Guangming; ZHU, Haochen et al. A review on management of waste three-way catalysts and strategies for recovery of platinum group metals from them. Online. *Journal of Environmental Management*. 2022, roč. 305. ISSN 03014797. Dostupné z: <https://doi.org/10.1016/j.jenvman.2021.114383>. [cit. 2024-10-11].

UYAR, Kangalli; Sinem Guler; UYAR, Umut a BALKAN, Emrah. Fundamental predictors of price bubbles in precious metals: a machine learning analysis. Online. *Mineral Economics*. 2024, roč. 37, č. 1, s. 65-87. ISSN 2191-2203. Dostupné z: <https://doi.org/10.1007/s13563-023-00404-z>. [cit. 2024-10-20].

VARSHINI, Anu; KAYAL, Parthajit a MAITI, Moinak. How good are different machine and deep learning models in forecasting the future price of metals? Full sample versus sub-sample. Online. *Resources Policy*. 2024, roč. 92. ISSN 03014207. Dostupné z: <https://doi.org/10.1016/j.resourpol.2024.105040>. [cit. 2024-10-20].

XIA, Jinsong a GHAHREMAN, Ahmad. Platinum group metals recycling from spent automotive catalysts: metallurgical extraction and recovery technologies. Online. *Separation and Purification Technology*. 2023, roč. 311. ISSN 13835866. Dostupné z: <https://doi.org/10.1016/j.seppur.2023.123357>. [cit. 2024-10-09].

XU, Xiaojie a ZHANG, Yun. Platinum and palladium price forecasting through neural networks. Online. *Communications in Statistics - Simulation and Computation*. S. 1-15. ISSN 0361-0918. Dostupné z: <https://doi.org/10.1080/03610918.2024.2330700>. [cit. 2024-10-20].

Contact address of the author(s):

Ing. Jakub Horák, MBA, PhD., International School of Management Slovakia, Duchnovičovo námestie 1, 080 01 Prešov, Slovak Republic, e-mail: horak@mail.vstecb.cz

Bc. Filip Hofmann, School of Expertness and Valuation, Institute of Technology and Business in České Budějovice, Okružní 517/10, 37001 České Budějovice, Czech Republic, e-mail: 28575@mail.vstecb.cz