

# Mladá veda

## Young Science

Špeciálne vydanie

# Mladá veda

## Young Science

### MEDZINÁRODNÝ VEDECKÝ ČASOPIS MLADÁ VEDA / YOUNG SCIENCE

Číslo 9, ročník 5., vydané v decembri 2017

ISSN 1339-3189

Kontakt: [info@mladaveda.sk](mailto:info@mladaveda.sk), tel.: +421 908 546 716, [www.mladaveda.sk](http://www.mladaveda.sk)

Fotografia na obálke: Château de Chambord. © Branislav A. Švorc, [foto.branisko.at](http://foto.branisko.at)

#### REDAKČNÁ RADA

*doc. Ing. Peter Adamišín, PhD.* (Katedra environmentálneho manažmentu, Prešovská univerzita, Prešov)

*doc. Dr. Pavel Chromý, PhD.* (Katedra sociálnej geografie a regionálneho rozvoje, Univerzita Karlova, Praha)

*prof. Dr. Paul Robert Magocsi* (Chair of Ukrainian Studies, University of Toronto; Royal Society of Canada)

*Ing. Lucia Mikušová, PhD.* (Ústav biochémie, výživy a ochrany zdravia, Slovenská technická univerzita, Bratislava)

*doc. Ing. Peter Skok, CSc.* (Ekomos s. r. o., Prešov)

*prof. Ing. Róbert Štefko, Ph.D.* (Katedra marketingu a medzinárodného obchodu, Prešovská univerzita, Prešov)

*prof. PhDr. Peter Švorc, CSc.*, predseda (Inštitút histórie, Prešovská univerzita, Prešov)

*doc. Ing. Petr Tománek, CSc.* (Katedra verejnej ekonomiky, Vysoká škola báňská - Technická univerzita, Ostrava)

#### REDAKCIA

*PhDr. Magdaléna Keresztesová, PhD.* (Fakulta stredoeurópskych štúdií UKF, Nitra)

*Mgr. Martin Hajduk* (Inštitút histórie, Prešovská univerzita, Prešov)

*RNDr. Richard Nikischer, Ph.D.* (Ministerstvo pro místní rozvoj ČR, Praha)

*Mgr. Branislav A. Švorc, PhD.*, šéfredaktor (Vydavateľstvo UNIVERSUM, Prešov)

*PhDr. Veronika Trstianska, PhD.* (Ústav stredoeurópskych jazykov a kultúr FSŠ UKF, Nitra)

*Mgr. Veronika Zuskáčová* (Geografický ústav, Masarykova univerzita, Brno)

#### VYDAVATEĽ

Vydavateľstvo UNIVERSUM, spol. s r. o.

[www.universum-eu.sk](http://www.universum-eu.sk)

Javorinská 26, 080 01 Prešov

Slovenská republika

© Mladá veda / Young Science. Akékoľvek šírenie a rozmnožovanie textu, fotografií, údajov a iných informácií je možné len s písomným povolením redakcie.

# KOMPARACE NEURONOVÝCH SÍTÍ A REGRESNÍCH ČASOVÝCH ŘAD PŘI ODHADU VÝVOJE RANNÍCH CEN PLATINY NA NEWYORSKÉ BURZE

COMPARISON OF NEURAL NETWORKS AND REGRESSIVE TIME SERIES IN  
ESTIMATING THE DEVELOPMENT OF THE PRICES OF PLATINUM ON THE NEW  
YORK STOCK EXCHANGE

**Marek Vochozka<sup>1</sup>, Pavel Rousek<sup>2</sup>**

Marek Vochozka působí jako rektor na Vysoké škole technické a ekonomické v Českých Budějovicích. Ve svém výzkumu se věnuje zejména tématům, jako jsou: metody komplexního hodnocení podniku, umělé neuronové sítě, finanční analýza a predikce budoucího vývoje společnosti. Pavel Rousek působí jako odborný asistent a interní auditor na Ústavu znaleství a oceňování Vysoké školy technické a ekonomické v Českých Budějovicích. Ve svém výzkumu a publikační činnosti se zabývá oblastí efektivnosti veřejného sektoru, podnikovými financemi, controllingem a interním auditem.

Marek Vochozka is a rector of Institute of Technology and Business in Ceske Budejovice. His research focuses mainly on topics such as: methods for comprehensive evaluation of the company, artificial neural networks, financial analysis and prediction of the future development of the company. Pavel Rousek acts as an assistant professor and internal auditor at the School of Expertness and Valuation of the Institute of Technology and Business in České Budějovice. In his research and publishing activities, he deals with areas of public sector efficiency, corporate finance, controlling and internal audit.

## **Abstract**

Platinum is a very rare metal, but it is very desirable for its very attractive properties. It is a very hard, heavy, and expensive metal that rarely exists either as pure platinum or as part of other elements. Platinum is used in a wide range of industries. Due to these characteristics, it is very important to analyze the platinum price and to predict its future development. For example, artificial neural networks, which are used in approximation, classification and also in time series prediction, are used for this purpose. The aim of the paper is therefore to

---

<sup>1</sup> Adresa pracoviště: doc. Ing. Marek Vochozka, MBA, Ph.D., Vysoká škola technická a ekonomická v Českých Budějovicích, Okružní 517/10, 370 01 České Budějovice  
E-mail: vochozka@mail.vstecb.cz

<sup>2</sup> Adresa pracoviště: Ing. Pavel Rousek, Ph.D., Ústav znaleství a oceňování, Vysoká škola technická a ekonomická v Českých Budějovicích, Okružní 517/10, 370 01 České Budějovice  
E-mail: rousek@mail.vstecb.cz

perform a regression analysis of the development of platinum prices on the New York Stock Exchange using neural networks and a simple linear regression. The partial aim is to compare these two methods and determine the most suitable ones for predicting the future development of platinum prices on the New York Stock Exchange. The analysis is made on the data on platinum prices in a time period exceeding 10 years. Altogether, this means 2,570 pieces of data. Processing is done in the Statistica software. Linear regression is performed on a data sample for linear, polynomial, exponential, logarithmic functions, as well as for spline function, multi-parameter weighted distances and multiple negative-exponential smoothing. Regression analysis using neural networks uses Multilayer Perceptron Networks (MLP) and Basic Radial Function Networks (RBF). A total of 1,000 neural structures are generated, of which 5, which exhibit the best characteristics, are preserved. The result is a prediction of platinum prices and the fact that neural networks are more suitable than simple linear regression for this prediction.

Key words: prediction, platinum, artificial neural networks, linear regression, time series

### **Abstrakt**

Platina je velmi vzácný kov, který je ovšem pro své velice přívětivé vlastnosti velmi žádaný. Jedná se o velmi odolný, těžký a drahý kov, který se vyskytuje opravdu jen vzácně buďto jako ryzí platina nebo jako součást ostatních prvků. Platina je využívána v celé řadě průmyslových oborů. Díky těmto charakteristikám je velice důležité cenu platiny analyzovat a predikovat její budoucí vývoj. K tomu slouží například i umělé neuronové sítě, které mají využití v aproximaci, klasifikaci a také právě v predikci časových řad. Cílem příspěvku je proto provést regresní analýzu vývoje ranních cen platiny na newyorské burze pomocí neuronových sítí a jednoduché lineární regrese. Dílčím cílem je porovnání těchto dvou metod a určení vhodnější z nich pro predikci budoucího vývoje ranních cen platiny na newyorské burze. Analýza je provedena na datech o ranních cenách platiny v době přesahující 10 let. Celkem se tedy jedná o 2 570 údajů. Zpracování je provedeno v softwaru Statistica. Lineární regrese je provedena na datovém vzorku pro lineární, polynomiální, exponenciální, logaritmickou funkci, dále pak pro funkci spline, mnohočlen vážených vzdáleností a mnohočlen negativně-exponenciální vyhlazování. Regresní analýza pomocí neuronových sítí používá vícevrstvé perceptronové sítě (MLP) a sítě základní radiální funkce (RBF). Generováno je celkem 1 000 neuronových struktur, z nichž 5, které vykazují nejlepší charakteristiky, je uchováno. Výsledkem je predikce ranních cen platiny a fakt, že neuronové sítě jsou pro tuto predikci vhodnějším nástrojem než jednoduchá lineární regrese.

Keywords: predikce, platina, umělé neuronové sítě, lineární regrese, časové řady

### **Úvod**

Platina (chemická značka Pt), latinsky platinum, je velice vzácný, mimořádně odolný, těžký a velmi drahý kov stříbřitě bílé barvy, který je strategickou komoditou pro průmysl v mnoha státech světa. Poptávka po platině se v posledních 30 letech více než zdvojnásobila. To je dáno především díky její chemické odolnosti a mechanickým vlastnostem (Reith aj., 2014). Dle Mergeta aj. (2002) se platina v přírodě vyskytuje opravdu velice vzácně, a to buď ryzí, nebo se vyskytuje s ostatními prvky platinových kovů v písku či v náplavech. Tento vzácný

kov je obsažen v zinku, niklu, mědi či v jiných slitinách, které jsou součástí platinových kovů, avšak lze ho jen velmi těžko oddělit. Dle autora je možné platinu nalézt převážně v oblasti pohoří Ural a v Jihoafrické republice. Mudda (2012) popisuje přírodní platinu jako nerost, který obsahuje patřičné množství železa. Je to velice pevný a těžký kov, který je nemagnetický, vyznačuje se především dobrou kujností a můžeme ho zařadit mezi ušlechtilé kovy.

Výroba platiny je podle Patela a Dawsona (2015) poměrně složitý proces, jelikož přírodní platina zahrnuje přibližně 25 % možných příměsí. Aby vznikl ryzí kov, je nutné o tyto příměsi platinu očistit. Platinu je proto důležité vyvařit či rozpustit v lučavce královské<sup>3</sup>, kde získá podobu mleté rudy. Po tomto procesu je nutné nechat působit hydroxid vápenatý, jenž umožní inkrustaci<sup>4</sup> ostatních kovů kromě platiny (Rehren, 2006).

Dle Brenana (2008) je platina ušlechtilý, kujný a odolný kov, který je využíván v mnoha různých průmyslových činnostech, jako v chemickém průmyslu, farmaceutickém průmyslu, sklářském průmyslu, v omezené míře se platina využívá i pro výrobu šperků, apod. V automobilovém průmyslu se platina využívá k výrobě katalyzátorů pro snižování emisí ve výfukových plynech. Ročně se tohoto kovu přibližně vytěží pouhých 150 tun. V současné době představuje platina 40-45 % světové poptávky (Almécija aj., 2016). Jak již bylo řečeno, platina má mnoho jedinečných fyzikálních a chemických vlastností. Ty jsou nepostradatelné pro mnoho technologií, průmyslových činností, ale také pro oblasti zdravotnictví či jiných oblastí, a proto se s tímto kovem obchoduje na světových trzích. (Ranganai a Kubheka, 2016). Dle autorů se však tento vzácný kov ve finančním sektoru využívá kratší dobu, než stříbro či zlato.

Dle Sverdrupa a Ragnarsdottir (2016) se světová cena platiny uvádí v trojských uncích (značka pro trojskou unci je Oz). Jedna Oz odpovídá 31,1034807 gramům. Platina se také využívá již přes 300 let jako uchovatel hodnoty. Co se týče investičních účelů, je tento drahý kov snadno dostupný, podobně jako stříbro či zlato, a to ve formě slitků a v některých případech i ve formě mincí. Platina se však řadí mezi průmyslové kovy, a proto se při jejím nákupu platí DPH (Kendall, 2004).

### **Umělé neuronové sítě**

Na základě uvedených informací lze konstatovat, že vývoj a predikce budoucí ceny platiny jsou velice důležité. K tomuto účelu slouží celá řada metod a modelů. V tomto příspěvku bude využita stále populárnější umělá inteligence, konkrétně pak umělé neuronové sítě (ANN – artificial neural network). Ty se snaží kopírovat procesy v lidském mozku a nervového systému pomocí počítačových zařízení. Tento pojem se poprvé objevil v biologii a psychologii. Využití umělých neuronových sítí však postupuje i do jiných oblastí a v současné době jsou široce používány pro řešení možných budoucích problémů, tedy pro již zmíněnou predikci hodnot (Pao, 2008). Dle Altuna, Bilgila a Fidana (2007) jsou umělé neuronové sítě ve velké míře používány v mnoha technických aplikacích a umožňují poskytovat různá řešení v odhadech problémů, optimalizaci či regresi. Neuronové sítě jsou využívány pro mnoho

<sup>3</sup> Lučavka královská je dýmavá žlutohnědá kapalina používaná pro rozpouštění obtížně rozpustných vzácných kovů. Jedná se o směs koncentrované kyseliny dusičné a kyseliny chlorovodíkové.

<sup>4</sup> Inkrustaci v tomto případě rozumíme vysrážení látek z roztoků.

různých účelů a je vhodné používat je pro náročné operace, které nelze analyticky identifikovat. Z tohoto důvodu se využívají zejména pro modelování velmi obtížných strategických rozhodnutí (Guresen a Kayakutlu, 2011). Dle Sáncheze a Melina (2015) je možné neuronové sítě aplikovat na aproximace funkcí, klasifikace a zejména na predikci časové řady. Neuronové sítě mají dle autorů velmi široké využití právě hlavně v oblasti analýzy časových řad. Časovou řadu přitom definujeme jako posloupnost prostorově a věcně srovnatelných pozorování, která jsou uspořádána z hlediska času.

Dle Sheikhana aj. (2013) na účelu časových řad a na povaze veškerých dat velmi záleží. Co se týče průběhu časových řad a neuronových sítí, neuronové sítě zachycují chování časových řad a snaží se nejlépe predikovat individuální datové body. Aby mohly neuronové sítě dobře pracovat s časovou řadou, je dle Hu a Hwang (2002) důležité neuronové sítě správným způsobem naučit. Z části původních časových řad se vytvářejí prvky pro učení a to takovým způsobem, že prvních  $n$  hodnot časových řad je dáno na vstup a následná hodnota je dána na výstup jako požadovaná. Následující krok spočívá v posunu časového okna o 1 a tím je vytvořen další prvek pro učení. Pro vstup je vybráno  $n$  hodnot, jako požadovaná je hodnota  $n + 1$ . Tímto způsobem je tedy vytvořena celá trénovací množina, která je složena ze seznamu prvků (Chen, Yang a Dong, 2006).

Cílem příspěvku je provést regresní analýzu vývoje ranních cen platiny na newyorské burze pomocí neuronových struktur a pomocí lineární regrese, poté obě metody porovnat a určit vhodnější z nich pro predikci budoucího vývoje ranních cen platiny na burze v New Yorku.

### **Data a použité metody**

Data pro analýzu budou pocházet z internetových stránek newyorské burzy, případně také Světové banky. Klíčovou hodnotou pro stanovení referenční ceny platiny, stejně jako u celé řady dalších komodit, je tzv. London fix Price (často bývá označován také jako London Fix). Tato cena je vyhlášována ve dnech, kdy je s platinou obchodováno v Londýně, tedy dvakrát denně. Dopolední London Fix Price je vyhlášována přesně v 09:45 (díky tomu se označuje jako AM) a odpolední je vyhlášována v 14:00 (označuje se tedy jako PM). London Fix Price je vyhlášována pravidelně, ovšem kromě 24. prosince (pokud je pracovním dnem) a 31. prosince, kdy je vyhlášována pouze dopoledne (v případě, že opět poslední den v měsíci prosinci připadá na pracovní den).

Stanovení London Fix Price začíná v okamžiku, kdy předsedající fixingová komise navrhne otevírací cenu, která se pohybuje v blízkosti spotové ceny platiny. Proces dále pokračuje tím, že jednotliví členové komise kontaktují svá obchodní oddělení a řeší, kdo a jaké množství platiny bude za danou cenu prodávat a nakupovat. Případně také dokáží cenu mírně koordinovat tak, aby nabídka a poptávka po platině vybraných největších obchodníků byla srovnána a nebyl mezi nimi žádný převis poptávky ani nabídky. Poté je stanovena konečná London Fix Price. Proces stanovení London Fix trvá cca 10-20 minut. Cena London Fix je stanovována ve třech měnách – amerických dolarech (USD), britských librách (GBP) a eurech (EUR) za jednu trojskou unci.

Analýza bude v tomto příspěvku provedena na datech London Fix Price AM v době mezi 3. lednem 2006 a 15. dubnem 2016. Jedná se tedy o ranní ceny platiny a celkově o 2570 údajů.

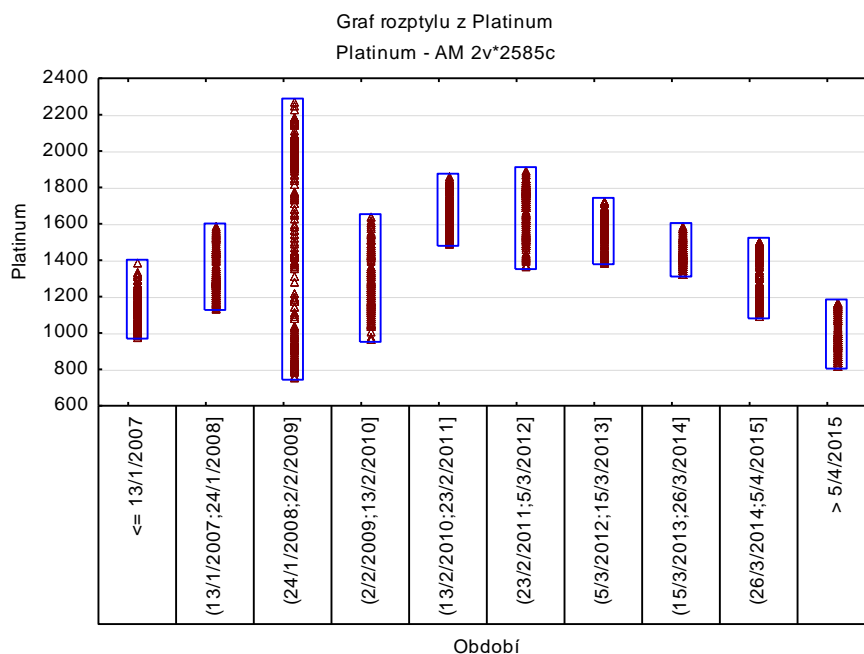
S odpoledními cenami tedy nebude uvažováno. Popisné charakteristiky datového souboru, tedy minimální, maximální, průměrná hodnota a rozptyl, jsou uvedeny v tabulce číslo 1.

Popisná charakteristika	Hodnota v USD
Minimální hodnota	756
Maximální hodnota	2276
Průměrná hodnota	1391,25416
Rozptyl	82380,3569

Tabulka 1 – Charakteristiky datového souboru

Zdroj: Autoři

Vývoj ceny platiny v čase je, i díky poměrně rozsáhlému datovému souboru, velice zajímavý. Na obrázku číslo 1 je uveden rozptyl hodnot v jednotlivých periodách sledovaného časového období (3. 1. 2006-15. 4. 2016).



Obrázek 1 – Graf rozptylu ceny platiny (London Fix AM)

Zdroj: Autoři

Zpracování dat bude provedeno v softwaru Statistica ve verzi 12 od společnosti DELL. Nejdříve bude provedena lineární regrese, následovat budou umělé neuronové sítě. Lineární regrese bude provedena na zkoumaném vzorku dat pro následující funkce:

- Lineární,
- Polynomiální,
- Exponenciální,
- Logaritmickou,
- Spline
- Mnohočlen vážených vzdáleností,
- Mnohočlen negativně-exponenciální vyhlazování.

Ze všeho nejdříve však bude spočítán korelační koeficient. Jedná se o závislost ceny platiny na čase. Budeme pracovat s hladinou významnosti na úrovni 0,95.

Poté bude provedena regresní analýza pomocí neuronových sítí. Generovány budou dva druhy neuronových sítí, a to vícevrstvé perceptronové síť (MLP) a neuronové síť základní radiální funkce (RBF). Za nezávislou proměnnou budeme považovat určený čas, zatímco za závislou proměnnou cenu platiny. Časová řada přitom bude rozdělena na tři soubory, a to trénovací, testovací a validační. Trénovací vzorek bude obsahovat 70 % vstupních údajů (na základě této množiny dat jsou generovány samotné neuronové struktury). V testovacím i validačním vzorku bude shodně 15 % vstupních dat. Obě tyto skupiny slouží pro ověření spolehlivosti nalezených neuronových struktur, resp. nalezeného modelu. Generováno bude celkem 1 000 neuronových sítí, z nichž bude uchováno 5 takových, které budou vykazovat nejlepší charakteristiky<sup>5</sup>. Skrytá vrstva bude obsahovat nejméně dva neurony, maximálně však 20. Síť RBF budou mít ve skryté vrstvě nejméně 21 neuronů, nejvýše pak 30. Pro MLP síť budeme, ve skryté i výstupní vrstvě, uvažovat distribuční funkce lineární, logistickou, atanh, exponenciální a funkci sinus. Ostatní nastavení ponecháme defaultní (podle nástroje ATS – automatická tvorba sítí).

Závěr porovná výsledky lineární regrese a regrese pomocí umělých neuronových sítí. Porovnání v tomto případě nebude probíhat formou analýzy reziduí (minimální, maximální hodnoty, rozptyl reziduí atd.), ale na úrovni expertního pohledu a zkušenosti hodnotitele, ekonoma.

## **Výsledky**

Tato část obsahuje výsledky získané pomocí lineární regrese a regrese pomocí neuronových sítí.

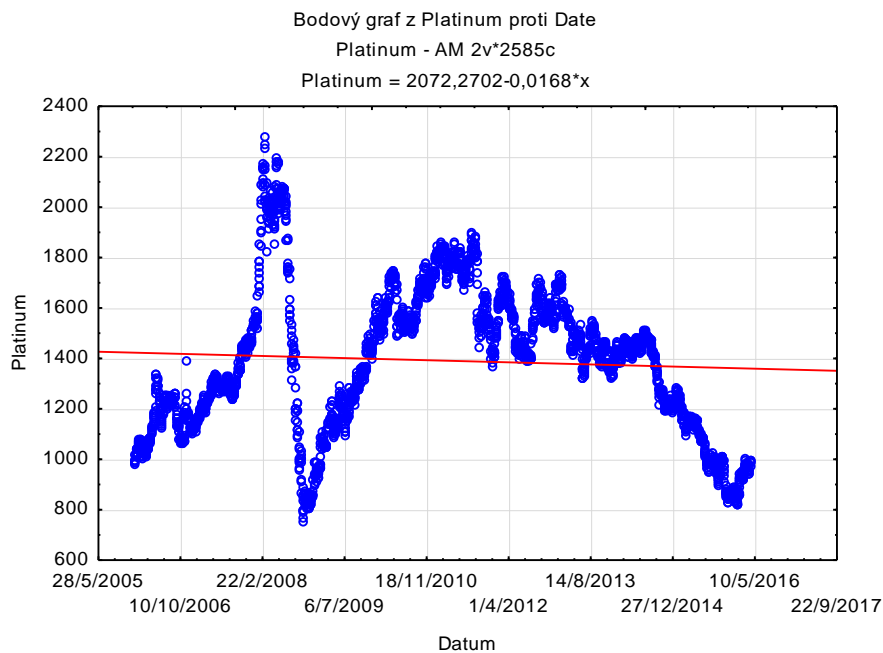
### ***Lineární regrese***

Korelační koeficient vychází -0,0638, což značí nevýznamnou statistickou závislost platiny na vývoji v čase. Sestaven byl bodový graf, ve kterém jednotlivé body byly proloženy regresní křivkou, v tomto případě lineární funkcí. Parametry přímky lze vidět na obrázku č. 2.

---


<sup>5</sup>Budeme se orientovat pomocí metody nejmenších čtverců. Generování sítí ukončíme, pokud nebude docházet ke zlepšení, tj. ke snižování hodnoty součtu čtverců. Uchováme tedy ty neuronové struktury, jejichž součet čtverců reziduí ku skutečnému vývoji platiny bude co nejnižší (ideálně nula).





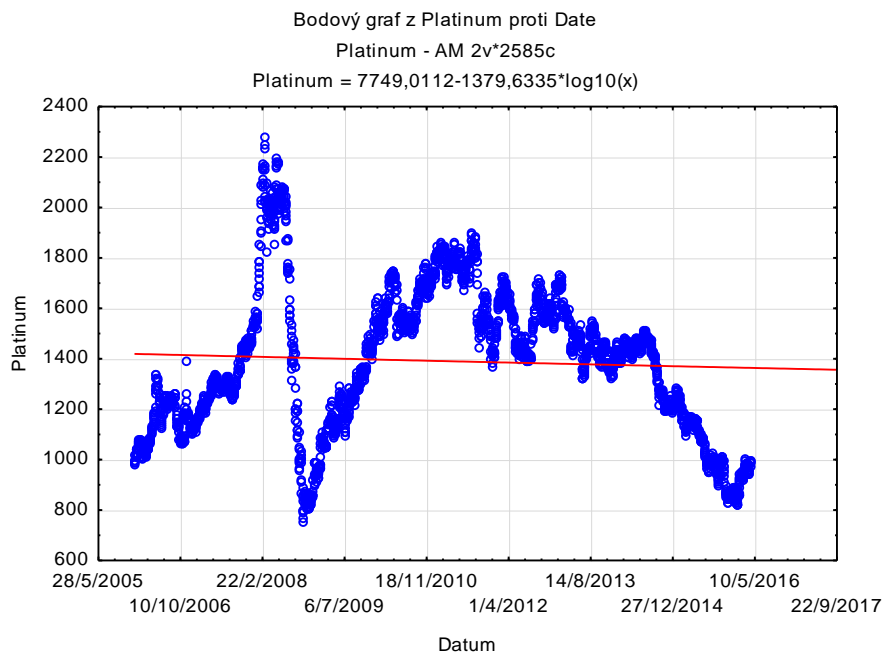
Obrázek 2 – Bodový graf ceny platiny proložený regresní křivkou - lineární funkcí  
Zdroj: Autoři

Plná čára přitom zobrazuje regresní funkci. Na obrázku č. 3 je znázorněno proložení bodového grafu London Fix Price polynomiální funkcí.



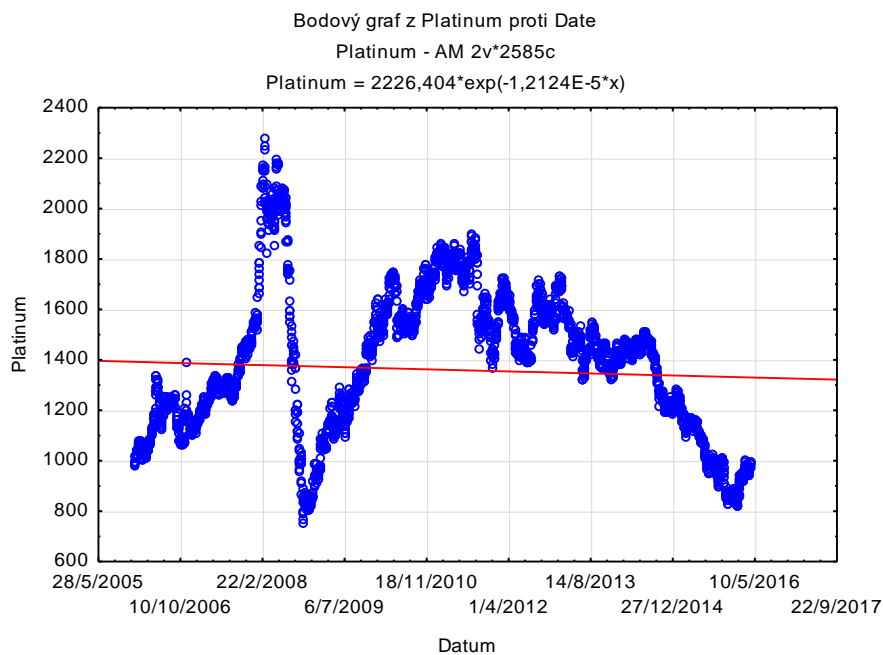
Obrázek 3 – Bodový graf ceny platiny proložený regresní křivkou - polynomiální funkcí  
Zdroj: Autoři

Stejně jako v případě lineární funkce i v tomto případě plná, červeně označená, čára představuje regresní křivku. Obrázek č. 4 představuje bodový graf proložený logaritmickou funkcí.




Obrázek 4 – Bodový graf ceny platiny proložený regresní křivkou - polynomiální funkcí  
Zdroj: Autoři

Obrázek číslo 5 znázorňuje bodový graf London Fix Price proložený exponenciální funkcí.



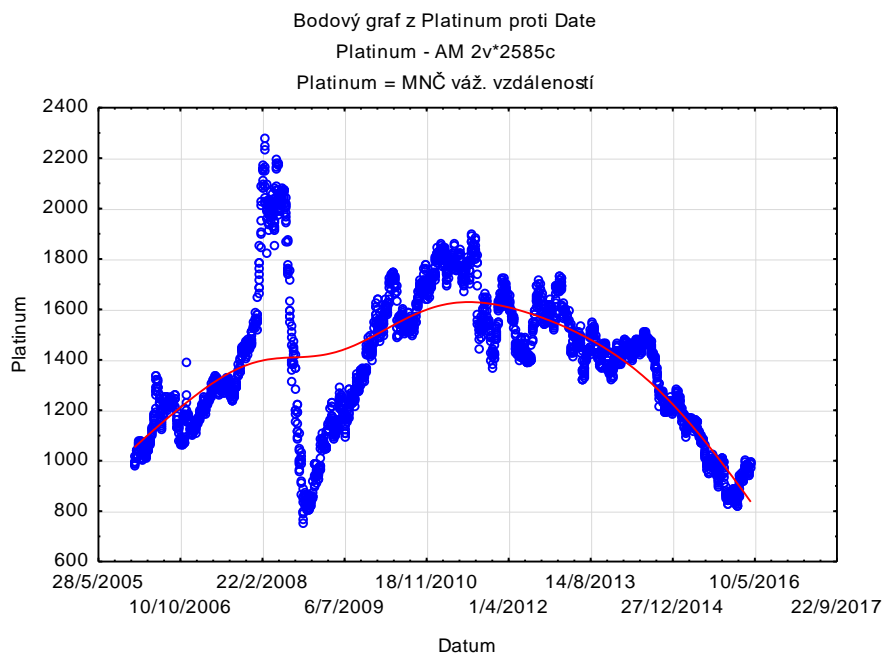
Obrázek 5 – Bodový graf ceny platiny proložený regresní křivkou - exponenciální funkcí  
Zdroj: Autoři

Bodový graf vývoje ceny platiny proložený funkcí spline je uveden na obrázku č. 6.




Obrázek 6 – Bodový graf ceny platiny proložený regresní křivkou – funkcí spline  
Zdroj: Autoři

Bodový graf vývoje cen platiny proložený funkcí získanou metodou nejmenších čtverců vážených vzdáleností je uveden na obrázku č. 7.



Obrázek 7 – Bodový graf ceny platiny proložený regresní křivkou – funkcí získanou metodou nejmenších čtverců vážených vzdáleností  
Zdroj: Autoři

Obrázek číslo 8 znázorňuje proložení London Fix Price funkcí získanou pomocí metody nejmenších čtverců negativně – exponenciálním vyhlazováním.



Obrázek 8 – Bodový graf ceny platiny proložený regresní křivkou - funkcí získanou metodou nejmenších čtverců – negativně exponenciální vyhlazování  
Zdroj: Autoři

Jak již bylo uvedeno, korelační koeficient tedy naznačuje nevýznamnou statistickou závislost cílové proměnné na vývoji v čase. Na základě hodnocení výsledků pouze optickým srovnáním vývoje London Fix Price AM a tvaru regresní křivky, při úvaze jednoduché lineární regrese, lze konstatovat, že nejbližše se vývoji ceny platiny přibližuje křivka proložená funkcí spline. Poměrně vhodná je ještě také křivka získaná metodou nejmenších čtverců – negativně-exponenciálním vyhlazováním. Ostatní křivky nedosahují významnějších přesností. Křivka získaná metodou nejmenších čtverců negativně-exponenciálním vyhlazováním hrubě kopíruje cenu platiny, která se minimálně vzdaluje od skutečného vývoje a vystihuje i globální extrém tohoto vývoje. Oproti tomu křivka získaná funkcí spline sleduje nejen globální extrém vývoje London Fix Price AM, ale také lokální extrém tohoto vývoje. Z hlediska možné predikce London Fix Price se opticky funkce jeví efektivně, avšak stále ještě poněkud nepřesně.

### ***Neuronové struktury***

Na základě stanoveného postupu bylo vygenerováno celkem 1 000 umělých neuronových struktur. Z nich bylo uchováno 5 sítí, které vykazují nejlepší parametry. Přehled těchto uchovaných sítí je uveden v tabulce číslo 2.

Index	Jméno sítě	Trénovací výkon	Testovací výkon	Validační výkon	Trénovací chyba	Testovací chyba	Validační chyba	Trénovací algoritmus	Chybová funkce	Aktivace skryté vrstvy	Výstupní aktivační funkce
1	MLP 1-15-1	0,996844	0,996372	0,997887	263,6006	266,7453	179,2822	BFGS (Quasi-Newton)	Sum. čtvr.	Exponenciální	Exponenciální
2	MLP 1-5-1	0,996864	0,996360	0,997892	261,5458	268,3624	180,2231	BFGS (Quasi-Newton)	Sum. čtvr.	Exponenciální	Exponenciální
3	MLP 1-3-1	0,996879	0,996382	0,997890	260,2581	266,5886	180,2352	BFGS (Quasi-Newton)	Sum. čtvr.	Exponenciální	Exponenciální
4	MLP 1-17-1	0,996855	0,996374	0,997892	262,2568	266,7241	179,3064	BFGS (Quasi-Newton)	Sum. čtvr.	Exponenciální	Exponenciální
5	MLP 1-8-1	0,996861	0,996385	0,997890	262,4653	265,8024	179,1128	BFGS (Quasi-Newton)	Sum. čtvr.	Exponenciální	Exponenciální

Tabulka 2 – Přehled uchovaných neuronových sítí

Zdroj: Autoři

Vybrané nejvhodnější sítě jsou pouze vícevrstvé perceptronové sítě s jednou skrytou vrstvou, přičemž ve vstupní vrstvě je jediná proměnná, a to čas. Ve skryté vrstvě obsahují neuronové sítě od 3 do 17 neuronů. Výstupní vrstva obsahuje logicky pouze jediný neuron a jedinou výstupní proměnnou – London Fix Price. Umělé neuronové struktury se neliší ani druhem použitých aktivačních funkcí ve skryté vrstvě a ani druhem výstupních aktivačních funkcí – všechny funkce jsou exponenciální.

Velmi zajímavý je určitě i trénovací, testovací a validační výkon. Obecně hledáme takovou síť, která má výkon ve všech množinách dat (zde je nutné připomenout, že rozdělení dat do množin proběhlo náhodně) ideálně stejný. U uchovaných sítí je výkon téměř totožný, což značí velmi dobrý výsledek. Chyba by přitom měla být co nejmenší. Bohužel je v tomto případě trénovací, testovací i validační chyba poměrně vysoká. Výkon jednotlivých množin dat lze znázornit v podobě korelačního koeficientu. Hodnoty jednotlivých množin dat podle konkrétních neuronových sítí jsou uvedeny v tabulce číslo 3.

	Platina trénovací	Platina testovací	Platina validační
1.MLP 1-4-1	0,996844	0,996372	0,997887
2.MLP 1-4-1	0,996864	0,996360	0,997892
3.MLP 1-8-1	0,996879	0,996382	0,997890
4.MLP 1-5-1	0,996855	0,996374	0,997892
5.MLP 1-10-1	0,996861	0,996385	0,997890

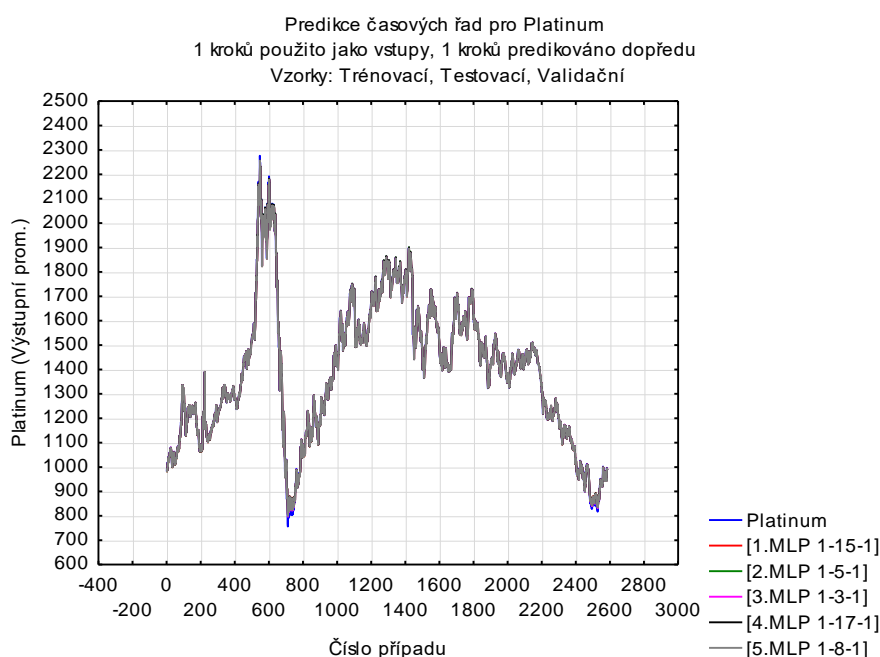
Tabulka 3 – Korelační koeficienty jednotlivých množin dat

Zdroj: Autoři

Tabulka potvrzuje, že výkon všech uchovaných neuronových struktur je víceméně totožný. Nepatrné rozdíly nemají na výkon jednotlivých sítí žádný vliv, jsou zanedbatelné.

Obrázek č. 9 zobrazuje spojnicový graf, který analyzuje skutečný vývoj London Fix Price (označeno jako Platinum) a zároveň predikuje vývoj ceny pomocí jednotlivých vygenerovaných sítí (ty jsou označeny pořadovým číslem uvedeným v tabulce číslo dvě a

počtem neuronů v jednotlivých vrstvách). Z obrázku lze vyčíst, že všechny neuronové sítě předpovídají vývoj ceny London Fix Price AM velmi obdobně (proto barevné křivky splývají v jednu). Důležitá ovšem není podobnost predikcí jednotlivých sítí, ale podobnost (resp. míra shodnosti) se skutečným vývoje ceny platiny. Také zde lze konstatovat, že uchované neuronové sítě vypadají na první pohled velmi zajímavě. Respektují totiž globální extrémní křivky hodnotící vývoj ceny platiny a mají také tendenci registrovat i lokální extrémní této křivky.



Obrázek 9 – Spojnicový graf – vývoj cen platiny predikovaný neuronovými sítěmi v porovnání se skutečnou cenou ve sledovaném období

Zdroj: Autoři

## Diskuse

Je nutné konstatovat, že každá predikce je obecně dána určitou mírou pravděpodobnosti, podle níž se vyplní. Když potřebujeme predikovat budoucí vývoj jakékoli proměnné, snažíme se na základě minulých dat co nejpřesněji odhadnout budoucí vývoj této proměnné. Do modelu lze přitom zahrnout většinu faktorů ovlivňujících cílovou veličinu. I přes to však dochází vždy k určitému zjednodušení dané reality. Pokaždé pracujeme s jistou mírou pravděpodobnosti, že se nějaký predikovaný scénář naplní. V případě lineární regrese i regrese pomocí neuronových sítí dochází ke zjednodušení, a to někdy i poměrně podstatnému. Tento příspěvek zahrnoval pouze dvě veličiny – vstupní (čas) a výstupní (London Fix Price). Článek tak naprosto odhlíží od jiných vstupních veličin, ač mají bezesporu vliv na konečnou cenu platiny. Jedná se například o vývoj národního hospodářství, politická situace státu, právní prostředí či překážky trhu apod. Přesto, možná i právě proto, že existuje nepřeberné množství faktorů ovlivňující cenu platiny, musí řešitel přemýšlet, zda prací s časovými řadami až příliš nezjednodušuje vývoj cílové proměnné či naopak jsou ostatní veličiny natolik nepodstatné, že vstupní veličina (čas) a výstupní veličina (London Fix Price) plně postačují.

Bereme-li v úvahu nemožnost predikovat vznik mimořádných situací<sup>6</sup> a jejich vliv na vývoj ceny platiny, je zjednodušení a tvorba relativně jednoduchého modelu na místě, přičemž výsledek je užitečný.

Cena platiny může být stanovena obecně na základě statistických, kauzálních a intuitivních metod. Tento příspěvek se zabýval srovnáním statistických metod, které podaly pouze možný rámec pro stanovení vývoje ranní ceny platiny na newyorské burze. Jak již bylo naznačeno, velmi důležité je dále pracovat s informacemi o možném budoucím vývoji ekonomického, politického a právního prostředí. Predikce těchto veličin je ovšem poměrně složitá. Pokud bychom ale byli schopni tyto veličiny predikovat, můžeme je následně promítnout do ceny platiny. V tomto případě ale přichází na řadu i osobnost hodnotitelů – ekonomů. Ti, na základě svých znalostí a erudovaných zkušeností, dokáží korigovat cenu stanovenou rámcově statistickými metodami a upřesňenou na základě kauzálních vazeb.

### **Závěr**

Konkrétním cílem příspěvku bylo provést regresní analýzu vývoje ranní ceny platiny na newyorské burze pomocí neuronových sítí a pomocí lineární regrese. Cílem také bylo obě metody porovnat a určit vhodnější z nich pro případnou predikci budoucího vývoje této ceny. Optickým pohledem se jevila z lineární regrese nejlépe křivka získaná pomocí funkce spline. Díky regresi pomocí umělých neuronových sítí jsme uchovali 5 nejvhodnějších neuronových struktur. Je možné konstatovat, že všechny jsou potenciálně použitelné. Podíváme-li se na výkon z pohledu koeficientu korelace, zůstávají k použití pouze neuronové sítě, mezi kterými není prakticky žádný rozdíl. Zajímavá by samozřejmě byla například analýza reziduí, která by zajisté určila z uchovaných neuronových sítí jednu nejlepší. To ovšem nebylo cílem tohoto článku. Pro analýzu a predikci ranních cen platiny na newyorské burze jsou tak vhodnější umělé neuronové sítě.

*Tento článek doporučil k publikování ve vědeckém časopise Mladá veda:  
Mgr. Zdeněk Caha, MBA, Ph.D.*

### **Seznam literatury**

1. ALMÉCIJA, Clara, Antonio COBELO-GARCÍA, Juan SANTOS-ECHEANDÍA a Miguel CAETANO, 2016. Platinum in salt marsh sediments: Behavior and plant uptake. *Marine Chemistry*. Roč. 185, s. 91-103. ISSN 0304-4203.
2. ALTUN, H., A. BILGIL a B.C. FIDAN, 2007. Treatment of multi-dimensional data to enhance neural network estimators in regression problems. *Expert Systems with Applications*. Roč. 32, č. 2, s. 599-605. ISSN 0957-4174.
3. BRENNAN, J. M., 2008. The Platinum-Group Elements: "Admirably Adapted" for Science and Industry. *Elements*. Roč. 4, č. 4, s. 227-232. ISSN 1811-5209.
4. CHEN, Yuehui, Bo YANG a Jiwen DONG, 2006. Time-series prediction using a local linear wavelet neural network. *Neurocomputing*. Roč. 69, č. 4-6, s. 449-465. ISSN 0925-2312.
5. GURESEN, Erkam a Gulgun KAYAKUTLU, 2011. Definition of artificial neural networks with comparison to other networks. *Procedia Computer Science*. Roč. 3, s. 426-433. ISSN 1877-0509.

---

<sup>6</sup>Vznik mimořádných situací lze předpovědět maximálně v krátkém horizontu, v dlouhém určitě nikoli.

6. HU, Yu Hen, a Jenq-Neng, HWANG, 2002. *Handbook of neural network signalprocessing*. BocaRaton: CRC Press. ISBN 978-084-9323-591.
7. KENDALL, Tom, 2004. The London Platinum and Palladium Market The role of the LPPM in the daily price fixings of platinum and palladium prices. *Platinum Metals Review*. Roč. 48, č. 1, s.13-14. ISSN 0032-1400.
8. MERGET, Rolf, Rupprecht KULZER, Annegret KNIFFKAB, Friedrich ALTICI, Rolf BREITSTADTBI a Thomas BRUENING, 2002. Platinum concentrations in sera of catalyst production workers are not predictive of platinum salt allergy. *International Journal of Hygiene and Environmental Health*. Roč. 205, č. 5, s. 347-351. ISSN 1438-4639.
9. MUDD, Gavin M, 2012. Key trends in the resource sustainability of platinum group elements. *Ore Geology Reviews*. Roč. 46, s. 106-117. ISSN 0169-1368.
10. PAO, Hsiao-Tien, 2008. A comparison of neural network and multiple regression analysis in modeling capital structure. *Expert Systems with Applications*, Roč. 35, č. 3, s. 720-727. ISSN 0957-4174.
11. PATEL, Anant a Richard DAWSON, 2015. Recovery of platinum group metal value via potassium iodide leaching. *Hydrometallurgy*. Roč. 157, s. 219-225. ISSN 0304-386x.
12. RANGANAI, Edmore a Sihle Basil KUBHEKA, 2016. Long memory mean and volatility models of platinum and palladium price return series under heavy tailed distributions. *Springer Plus*. Roč. 5, č. 1. ISSN 2193-1801.
13. REHREN, Thilo, 2006. The Minting of Platinum Roubles. *Platinum Metals Review*. Roč. 50, č. 3, s. 120-129. ISSN 0032-1400.
14. REITH, F., S.G. CAMPBELL, A.S. BALL a A. PRING, 2014. Platinum in Earth surface environments. *Earth-Science Reviews*. Roč. 131, s. 1-21. ISSN 0012-8252.
15. SÁNCHEZ, Daniela a Patricia MELIN, 2015. Modular Neural Networks for Time Series Prediction Using Type-1 Fuzzy Logic Integration. In: P. MELIN, O. CASTILLO a J. KACPRZYK. *Design of Intelligent Systems based on Fuzzy Logic, Neural Networks and Nature-Inspired Optimization*. Springer-Verlag Berlin, Germany, s.141-145.
16. SHEIKHAN, Mansour, Najmeh MOHAMMADI, Hissam TAWFIK a Eshel BEN-JACOB, 2013. Time series prediction using PSO-optimized neural network and hybrid feature selection algorithm for IEEE load data. *Neural Computing and Applications*. Roč. 23, č. 3-4, s. 1185-1194. ISSN 0941-0643.
17. SVERDRUP, Harald U. a Kristin Vala RAGNARSDOTTIR, 2016. A system dynamics model for platinum group metal supply, market price, depletion of extractable amounts, ore grade, recycling and stocks-in-use. *Resources, Conservation and Recycling*. Roč. 114, s.130-152. ISSN 0921-3449.