

Může být strojové učení užitečné ve financích podniku a jeho ocenění?

Přehled současného výzkumu[#]

*Veronika Staňková**

Úvod

S napětím očekávám, jak se promění obor financí podniku a jeho oceňování v důsledku nových technologií. Příchod počítačů a internetu v minulosti již zásadní změnu způsobil. Bude strojové učení další krok? Může být strojové učení užitečné ve financích podniku a jeho ocenění?

Tento článek si klade za cíl udělat přehled o současném výzkumu v oblasti aplikací strojového učení ve financích podniku a jeho oceňování. V současné době se publikuje tak velké množství vědeckých článků v oblasti aplikace strojového učení, že je obtížné se v nich zorientovat. Tím spíše pro většinu ekonomů, kteří nemají znalosti o strojovém učení. Záměrem tohoto článku je na základě rešerše současné literatury poskytnout základní přehled o tom, co strojové učení je a jaký je současný stav poznání v oblasti financí podniku a jeho oceňování. Tento článek by měl pomoci zorientovat se v perspektivách strojového učení těm, kteří se jím doposud nezabývali, ale chtěli by si udržet přehled o moderních trendech.

Struktura dalšího textu je následující: Nejprve popíši metodologii a zdroj dat. Následně zodpovím následující výzkumné otázky:

- Význam strojového učení: Co to strojové učení vlastně je a jaké jsou jeho výhody a nevýhody oproti běžným (statistickým) predikčním modelům?
- Stručný přehled modelů strojového učení: Jaké modely strojového učení existují a který z nich je „nejlepší“?
- Oblasti využití strojového učení ve financích: V jakých podoblastech financí podniku se v současnosti strojové učení aplikuje?
- Shrnutí: Může být strojové učení ve financích podniku a oceňování užitečné?

Metodologie

Vzhledem k rostoucímu zájmu o strojové učení (dále také ML, z angl. machine learning) vzniklo velké množství primárních článků (tj. článků, které testují konkrétní ML model na reálných datech). Za poslední tři dekády vzniklo v rejstříku Web of Science více než několik tisíc relevantních studií (jen kombinace „neural network“ a „finance“ má přes pět tisíc

[#] Článek je zpracován jako jeden z výstupů výzkumného projektu IG104020, který je realizován na Fakultě financí a účetnictví VŠE Praha.

^{*} Ing. Veronika Staňková, doktorand, Katedra financí a oceňování podniku, Fakulta financí a účetnictví, Vysoká škola ekonomická v Praze.

výskytů na Web of Science) a dle zjištění Warin a Stojkov, 2021, str. 8, kteří zmapovali frekvenci výskytu ML klíčových slov na časové ose, je zřejmé, že každým rokem jejich počet exponenciálně roste.

Vedle primárních článků lze nalézt přehledové články (tzv. metastudie), které se vyznačují tím, že zpracovávají informace z několika primárních článků naráz. Několik takových existuje i pro oblast aplikace strojového učení ve financích podniku a jeho oceňování, ale na základě mých zjištění nejsou jednotlivé metastudie reprezentativním přehledem, neboť žádný nepokrývají zkoumanou oblast komplexně (vzhledem k počtu primárních článků možná ani není možné obsáhnout). Z tohoto důvodu je nepovažuji za ucelený přehled vhodný pro začátečníka. Abych doplnila chybějící agregovaný pohled, soustředila jsem se na zpracování přehledu publikovaných metastudií (čili „metastudie podkladových metastudií“) s cílem v maximální míře pokrýt existující literaturu ke zvolenému tématu.

Data

Vzorek metastudií jsem identifikovala kombinací automatického a ručního zpracování pro zajištění optimálního výsledku na základě těchto kritérií:

- kombinace anglických klíčových slov v názvu článku, které dle mého názoru nejlépe popisují přehledový článek v oblasti strojového učení ve financích¹;
- článek byl publikován v posledních třech letech, abych zajistila, že se budu zabývat pouze nejaktuálnějšími výzkumy. Metastudie mají navíc ze své podstaty oproti nejnovějším primárním výzkumům vždy zpoždění;
- vyloučení článků evidentně nesouvisejících s tématem aplikace strojového učení ve financích podniku a jeho ocenění na základě ručního vyhodnocení názvu článku;
- zařazení v databázi Scopus (nezohledňovala jsem počet citací) a
- dostupnost článků v některé z databází EBSCO, ProQuest, JSTOR a Google Scholar.

Celkem bylo vybráno 14 metastudií. Zkoumané metastudie jsou prezentovány v Tabulce 1 na další straně, včetně informace o počtu primárních článků, které byly v dané metastudii analyzovány a z jakého období tyto primární články pocházejí.

¹ Klíčová slova tvořila tři množiny, z nichž musel být nalezen průnik, tj. alespoň jedno slovo z každé skupiny. První skupina popisuje požadovaný formát metastudie (tj. jedno ze slov "review" nebo "research" nebo "survey" nebo "literature" nebo "progress" nebo "analysis" nebo "note"), druhá skupina vyjadřuje souvislost s ML ("machine learning" nebo "deep learning" nebo "neural" nebo "clustering" nebo "random forest" nebo "artificial intelligence" nebo "prediction" nebo "tree") a třetí skupina definuje oblast financí (slova "finance" nebo "equity" nebo "accounting" nebo "stock" nebo "financial" nebo "company" nebo "business").

Tab. 1: Přehled zkoumaných metastudií

Rok vydání	Článek	Počet primárních článků	Analyzované období
2019	[4]	130	2005-2018
2019	[12]	n/a	2001-2018(*)
2019	[15]		2004-2018(*)
2019	[2]	34	1999-2019
2020	[6]	40	2014-2018
2020	[11]	n/a	1998-2018
2020	[8]	33	2017-2020
2020	[17]	n/a	2005-2019 (*)
2020	[14]	140	2005-2019
2021	[7]	124	2017-2019
2021	[1]	27	1994-2019
2021	[16]	50	1990-2019
2021	[3]	58	1995-2019
2021	[18]	5053	1990-2021

Zdroj: vlastní zpracování

Význam strojového učení

O strojovém učení se říká, že se dokáže z poskytnutých vstupních dat sám „učit“. Princip „učení se“ ML modelu, zjednodušeně řečeno, spočívá v tom, že proces tvorby predikčního modelu (model fitting) probíhá uvnitř „automaticky“ analýzou poskytnutých dat. ML model se z poskytnutých dat sám pokouší najít takovou matematickou funkci (čili takové nastavení vnitřních parametrů), která bude z vysvětlujících proměnných predikovat optimální výsledek (např. vysvětlovanou proměnnou). Správné nastavení vnitřních parametrů se hledá automaticky, v iteracích a pomocí integrovaného optimalizačního mechanismu. Kromě vnitřních parametrů je ML model také definován vybranými hyperparametry (v angličtině také tuning parameter), tj. parametry zadanými zvnějšku, autorem modelu s cílem dál vylepšit vytvořený model. Všechny možné kombinace vnitřních parametrů (vytvářející aproximační funkci) se nazývají prostor hypotéz (hypothesis space). Různé ML algoritmy mají odlišné prostory hypotéz, a proto se hodí pro řešení různých otázek.

ML tvoří své predikce pouze na základě poskytnutých dat. Žádný ML model schopen předpovědět něco, co v poskytnutých datech není zachyceno – v tomto je stejný jako běžné statistické modely.

Princip metody strojového učení se popisuje v odborné literatuře od 50. let minulého století (Ghoddusi a kol., 2019, str. 1), ale teprve během minulé dekády se díky rostoucí výpočetní kapacitě (viz Moorův zákon²) a rostoucímu množství a dostupnosti elektronických dat naplno rozvinul potenciál ML.

Modely strojového učení se rozlišují na *učení s učitelem* (supervised) a *učení bez učitele* (unsupervised). Pro učení s učitelem jsou vstupem pro model spárovaná pozorování vysvětlující proměnné (v terminologii ML se nazývají také vstupní atributy, angl. input

² Moorův zákon je pojmenovaný po spoluzakladateli společnosti Intel, který v roce 1965 předpověděl, že se bude počet transistorů umístěných na integrovaný obvod každý rok zdvojnásobovat (později autorem upraveno na frekvenci každé dva roky). Počet zapojených transistorů přímo ovlivňuje výpočetní výkon.

variables nebo features) a vysvětlované proměnné (v ML se nazývá také cílový atribut). Učení bez učitele má k dispozici pouze vysvětlující proměnnou (bez vysvětlované). Podle varianty modelu se mění i cíl predikce:

- Algoritmy učení s učitelem jsou natrénované na vstupních datech, aby predikovaly vysvětlovanou proměnnou pro budoucí pozorování vysvětlujícími proměnnými.
 - Pokud je vysvětlující proměnná spojitá, jedná se o *regresní úlohu* (např. tržní cena), nebo
 - pokud je vysvětlující proměnná kategorická, jedná se o *klasifikační úlohu* (např. určit trend, zda cena bude růst, nebo klesat).
- Naopak algoritmy učení bez učitele mají za cíl zjednodušit (snížit dimenzionalitu) vstupních dat tím, že identifikují spolu související skupiny (clusters) ve *shlukovacích úlohách* anebo jiné důležité vztahy v datech (patterns and correlations).
- Část literatury uvádí jako samostatnou kategorii také tzv. *učení posilováním* (RL, z angl. reinforcement learning), ve kterém pro jednotlivá pozorování není k dispozici údaj o vysvětlované proměnné, ale je poskytnuta zpětná vazba (pozitivní, nebo negativní) v reakci na rozhodnutí. (Mueller a Massaron, 2016, str. 169) Využití RL se nachází především v (hardwarové) robotice. Ve financích podniku rozšířené RL není.

Specifickou kategorií jsou algoritmy na *zpracování přirozeného jazyka* (NLP, z angl. natural language processing). NLP funguje skrz text-mining např. finančních zpráv z Reuters, Bloomberg, textů z výročních zpráv, příspěvků ze sociálních sítí a jiných korpusů textu. NLP algoritmus umí odhadnout např. převládající sentiment na trhu. Následně pak informace o převládajícím sentimentu může být integrována jako vysvětlující proměnná do komplexních modelů. Konkrétně i v oblasti akciového trhu se totiž ukazuje, že určitý sentiment v krátkém horizontu může vysvětlit odchylky ceny pozorované na trzích (Vachhani a kol., 2019, str. 9).

Přednosti strojového učení

Analyzovaná literatura se víceméně shoduje, že ML modely většinou překonávají predikční schopnost běžných statistických modelů (např. Sezer a kol., 2019, str. 1 a Singh a kol., 2021, str. 6). Analyzované články popisují především tyto benefity ML:

- Výborné výsledky predikční přesnosti ML modelů. Vysoká schopnost predikce je dána vysokou flexibilitou ML modelů, která umožňuje zpracovat komplexní nelineární vysokodimenziální vztahy uvnitř dat. (Ghoddusi a kol., 2019, str. 11, 27)
- Možnost zpracování heterogenních dat ve velkých objemech, které mohou být ve strukturované (např. tabulky s čísly), ale i v nestrukturované podobě (např. obrázky, text). (Ghoddusi a kol., 2019, str. 28)
- Menší citlivost některých ML modelů na kvalitu vstupních dat (chybějící pozorování, kolinearita pod.) ve srovnání s tradičními statistickými modely, takže není nutné manuálně upravovat hrubá data (očisťovat o sezónnost, stacionarizace časové řady, hledat strukturální změny, řešit heteroskedasticitu apod.). (Ghoddusi a kol., 2019, str. 28)

- Již naučené ML modely lze v některých případech použít pro jiný úkol (transformovat) a generovat „úspory z rozsahu“. (Ghoddusi a kol., 2019, str. 29)

Limitace strojového učení

Na druhou stranu se v literatuře objevují i upozornění na limitace strojového učení. Patří mezi ně především následující:

- Nutnost velkých dat je základní podmínkou aplikace strojového učení, která může limitovat využití v mnoha oblastech, např. v makroekonomii, kde často bývá jen omezený počet pozorování. (Ghoddusi a kol., 2019, str. 31)
- Existuje riziko přeučení (overfitting), které spočívá v tom, že se model naučí i z šumu (o ničem nevypovídající náhodné složce) v poskytnutých datech. To se projeví tím, že predikce nových pozorování, se kterými se model ještě nesetkal, již nemá dostatečnou přesnost. V důsledku přeučení není model schopen generalizace pro nová data. V podstatě každý (statistický) predikční model trpí rizikem přeučení. (Ghoddusi a kol., 2019, str. 29) Nicméně u ML je toto riziko o to větší, že je velmi flexibilní (model se dokáže naučit i komplikované nelineární vztahy v datech). Z hlavní výhody ML se tedy stává i jeho slabina. Proto podle mého názoru neplatí, že čím komplikovanější ML model (typicky neuronové sítě), tím je zaručena jeho větší úspěšnost. To platí obzvlášť v oblasti financí podniku, kde obvykle není zajištěn dostatek kvalitních dat pro bezproblémové učení velmi složitých modelů

V praxi se riziko přeučení snižuje tím, že se dataset rozdělí na (i) trénovací data, (ii) validační data a (iii) testovací data. V situaci dostatku zdrojových dat je typický poměr rozdělení dat 50 %, 25 % a 25 % dle Hastie a kol. 2001 (str. 196). Doporučený postup je (tamtéž) takový, že:

- (i) ML algoritmus se nejprve učí na trénovacích datech (tvorba modelu optimalizací vnitřních parametrů modelu),
- (ii) Validační data se použijí pro nezávislý odhad predikční chyby daného modelu (evaluace) při výběru tzv. hyperparametrů modelu (parametry modelu, které jsou zadány autorem manuálně) a
- (iii) finální vyhodnocení vybraného modelu je provedeno na základě modelem do té doby neviděných testovacích datech.

Protože komplexnost modelu závisí na kvalitě dat, očištěním vstupních dat se dá také snížit riziko přeučení. (Huang a kol., 2020, str. 18).

- Netransparentnost (black box nature) je další z výtek, která je strojovému učení veřejností vytýkána. Nevýhoda spočívá v tom, že není zřejmé, jakým způsobem vyhodnotil algoritmus efekt různých proměnných a jak k prezentovanému výsledku došel (ve srovnání s interpretovatelností např. regresních koeficientů v lineárním regresním modelu). Tady bych ale chtěla upozornit na to, že to neplatí plošně pro všechny ML modely stejně, neboť některé ML modely jsou méně transparentní než jiné (o tomto detailněji při popisu jednotlivých modelů).

Ghoddusi a kol., 2019, str. 31 k tomuto poznamenávají, že ve vyhodnocení, jak významná nevýhoda je netransparentnost ML modelu, závisí také na tom, pro jaký účel se predikce (výstup) ML modelu používají, resp. jestli je kladen důraz na *interpretovatelnost* výsledku nebo na *výsledek* predikce. Typicky v oblastech jako je trading nebo korporátní plánování je důležitý spíše konkrétní výsledek, zatímco typicky pro vědecký výzkum určitého fenoménu je spíše důležité pochopení, jak tento fenomén vzniká (interpretovatelnost).

Strojové učení se typicky nezabývá statistickým testováním významnosti vysvětlujících proměnných, ale spíše ověřuje přesnost modelu porovnáním predikce pro testovací data se skutečností (Ghoddusi a kol., 2019, str. 32).

Stručný přehled modelů strojového učení

Metoda podpůrných vektorů (SVM, z angl. support vector machine)

SVM technika se používá především pro klasifikační úlohy. Spočívá v tom, že namapuje data pomocí jádrové transformace (kernel transformation) do vícedimenziálního prostoru, který pak lineárně separuje. Separace probíhá tak, že v prostoru maximalizuje odstup (maximal margin) mezi skupinami čili seskupuje pozorování tak, aby identifikované skupiny byly navzájem co nejvíce odlišné.

Výhody:

- Výhoda spočívá SVM v tom, že na jedné straně dokáže vystihnout nelineární vztahy mezi daty (i časových řad), ale nestává se tak komplexní jako neuronové sítě, takže netrpí tolik na riziko přeučení se. (Ghoddusi a kol., 2019, str.24)
- SVM obecně vykazuje vysokou přesnost predikce. (tamtéž)
- SVM je schopna tolerovat proměnné, které jsou pro predikci nerelevantní (redundantní). (tamtéž)

Nevýhody:

- Algoritmus SVM je těžko vysvětlitelný (tamtéž), takže následná interpretace je obtížná.
- SVM model se špatně škáluje, např. pokud model natrénovaný na 10 tis. pozorování funguje dobře, neznamená to, že bude také fungovat na datasetu obsahujícím 100 tis. pozorování (Mueller a Guido, 2016, str. 106)

Rozhodovací stromy (Decision trees)

Rozhodovací stromy jsou hierarchický nelineární systém založený na rekurzivním binárním dělení. Každý uzel (node) se dělí na dvě větve (branch), poslední řada uzlů s odpovědí se nazývá list (leaf nebo answer node). Dělení nodu probíhá na základě vhodného atributu a vhodné hraniční hodnoty atributu tak, aby rozdělením došlo k co nejvyššímu zlepšení statistického ukazatele neuspořádanosti systému (impurity measure, např. gini index,

entropie, informační zisk), plní úlohu optimalizačního mechanismu (ztrátové funkce). Statistický ukazatel neuspořádanosti systému zajišťuje, aby byl datový prostor rozdělen na dvě skupiny, které budou co nejvíc homogenní. Nejvyšší přesnosti a efektivity pro testovací data (prevence přeučení) se dělá na základě prořezávání (pruning) stromu od listů ke kořenu, při kterém se rozhodovací strom zjednodušuje tím, že se odstraňují dělení (uzle), které nemají dostatečnou predikční schopnost.

Komplexnější varianta rozhodovacích stromů jsou náhodné lesy (random forests), ve kterém se spojí několik rozhodovacích stromů, každý je vytvořený jako náhodná podmnožina původních dat.

Výhody:

- Rozhodovací stromy jsou koncepčně jednoduché (Hastie, 2001, str. 266) a lze je jednoduše graficky znázornit a interpretovat (neplatí už tolik pro náhodné lesy) (Hastie, 2001, str. 267).
- Algoritmus nevyžaduje předchozí přípravu dat, obzvlášť rozhodovací stromy jsou velmi robustní vůči kvalitě vstupních dat. (Mueller a Guido, 2016, str. 85)

Nevýhody:

- Rozhodovací stromy jsou citlivé na to, že i malá změna v datech vede k velké variabilitě predikčních výstupů. Tato nestabilita souvisí s hierarchickou strukturou, která je pro rozhodovací stromy charakteristická. (Hastie, 2001, str. 275).
- Ve výzkumech jsem se častěji setkala s náhodnými lesy než s jednoduchými rozhodovacími stromy, což zřejmě souvisí s tím, že náhodné lesy a další složitější modely založené na rozhodovacích stromech mají lepší schopnost generalizace (Mueller a Guido, 2016, str. 85).

Neuronové sítě

Hluboké učení (DL, z angl. deep learning) je podoblast ML, která využívá ke svému učení umělou neuronovou síť (NN, z angl. neural network anebo artificial neural network). Slovo „neuronové“ v názvu vychází z inspirace propojení biologických neuronů do sítě v mozku. Architektura NN má totiž minimálně tři propojené vrstvy paralelně zapojených neuronů (nods): (i) vrstvu vstupů (input layer), (ii) skryté vrstvy (hidden layers) a (iii) vrstvu výstupů (output layer). Označení „hluboké“ se vztahuje k tomu, že moderní NN jsou vytvářeny několika desítkami až dokonce stovkami skrytých vrstev. Počet neuronů v jedné vrstvě a počet (skrytých) vrstev se liší v každém konkrétním modelu (jde o tzv. hyperparametr modelu) a závisí především na komplexitě modelovaného jevu. Každý neuron je napojen na každý neuron v další vrstvě a ve vrstvě předchozí. Díky tomu se v každé další vrstvě akumuluje výsledek i z předchozích vrstev NN. Neuron ve skryté vrstvě je definován lineárním prediktorem a nelineární aktivační funkcí. Proces učení pak probíhá podle zvoleného optimalizačního algoritmu iteracemi parametrů (vah) v jednotlivých vrstvách, dokud se nedosáhne kritéria, které proces zastaví (buď byla chyba predikce ve vrstvě výstupu vyhodnocena jako dostatečně malá anebo byl proveden maximální počet iterací). Optimalizace probíhá jinými slovy tak, že neuron dostane tím větší váhu, čím lépe přispívá ke správné odpovědi (čili výsledku blížící se pozorování vysvětlované proměnné v tréninkovém data setu).

V literatuře se skupina DL modelů dále dělí na několik typů, z nichž některé velmi stručně uvedu, protože se v analyzované literatuře objevují:

- RNN (z angl. recurrent neural network) se typicky používá pro časové řady a sekvenční data (text, řeč), protože jsou uzpůsobené k tomu, aby si ve vnitřní paměti uchovala znalost o delším časovém úseku. (Sezer a kol., 2019, str. 8) Nevýhoda je v tom, že učení RNN „s dlouhou pamětí“ se stává velmi komplexní (je obtížné najít optimální váhy pro dlouhodobé vztahy).
- LSTM (z angl. long short term memory) je speciálním typem RNN, která je uzpůsobená tomu, aby si kromě dlouhodobých hodnot pamatovala i krátkodobé hodnoty díky kombinaci aktivačních funkcí. Kromě častého využití ve financích (finančních časových řadách) (viz Sezer a kol., 2019, Huang a kol., 2020 a Vachhani a kol., 2019) je dle (Sezer a kol., 2019, str. 9) LSTM široce využívána pro rozeznávání řeči, zpracování přirozeného jazyka, rozeznávání rukopisného textu apod.

Existují i další DL modely, ale protože se v analyzovaných článcích neobjevovaly, tak se jim v tomto článku nebudu detailněji věnovat.

Výhody:

- NN (především DL) dosahuje velmi vysokých ukazatelů přesnosti predikce (Ghoddusi a kol., 2019, str. 24). Pokud je k dispozici dostatek trénovacích dat, výpočetní kapacity a času, tak NN často překonávají jiné algoritmy. (Mueller a Guido, 2016, str. 119)

Nevýhody:

- Algoritmus DL je velmi netransparentní, takže jeho zdůvodnění (následná interpretace) je obtížné. (Ghoddusi a kol., 2019, str. 24)
- Vysoká náročnost na množství dat a proces učení. (tamtéž)
- Vysoké riziko přeučení se. (tamtéž)
- Nedokáže tolerovat chybějící hodnoty, irelevantní a redundantní proměnné. (tamtéž)

Rozvíjející oblastí ML výzkumu jsou tzv. hybridní modely (také ensemble models), které kombinují 2 a více samostatných predikčních modelů (lze přitom míchat ML a běžné statistické modely dohromady). Dle (Vachhani a kol., 2019, str. 2) jsou hybridní modely zpravidla založené na některém z typů NN modelu a ukazuje se, že hybridní modely přinesou slibné výsledky (Vachhani a kol., 2019, str. 5)

Preferované ML modely

Metastudie, která popisuje všechny typy ML modelů (Vachhani a kol., 2019), ukazuje relativně rovnoměrné rozdělení využití různých ML modelů a z nich nejčastěji SVM (23 %).

Většina zkoumaných metastudií se však soustředí na primární studie využívající pouze hluboké učení. Z toho se dá přinejmenším dovodit, že hluboké učení je momentálně vědecky

zajímavější. Dále mne zaujalo, že metastudie zaměřené na hluboké učení nejsou jednotné v tom, jaký ML model je preferován v primárních člancích. Není tedy možné identifikovat jeden nejspěšnější model na základě analyzovaných metastudií.

Z toho vyvozují, že neexistuje jeden „nejlepší“ ML model, ale že pro různá využití připadá různé, nebo i více možných modelů. Spíše je důležité zvážit výhody a nevýhody v konkrétní situaci (např. kvalita dat, velikost dat, zaměření na predikci, nebo interpretaci apod.). V praxi výzkumníci obvykle zpracují několik různých ML modelů. Jednotlivé modely pak mezi sebou porovnávají (někdy i vůči běžným statistickým modelům) a následně z nich vybírají ten, který v dané výzkumné otázce docílil nepřesnější predikce.

Sezer a kol., 2019, str. 40-41 se domnívají, že z části je volba použití ML modelů závislá také na popularitě (a úspěšnosti) v předchozích výzkumech.

Oblasti využití strojového učení ve financích

Ve financích podniku a jeho oceňování často vzniká potřeba predikovat budoucí hodnoty vybraných finančních ukazatelů na základě historických časových řad. Strojové učení je velmi silné ve vytváření predikcí, takže není překvapivé, že strojové učení je využíváno právě na predikce finančních časových řad. Zajímalo mne v jakých výzkumech konkrétně nachází strojové učení největší uplatnění.

Studie Sezer a kol., 2019, str. 39 a Kuizinienė a Krilavičius, 2020, str. 65 se shodují, že mezi aplikacemi jednoznačně převládá cíl predikovat ceny na kapitálovém trhu. Z analyzovaných 140 primárních výzkumů více než 70 % se zabývalo akciovým trhem, a to buď ve formě odhadu budoucí ceny konkrétní akcie, akciového indexu nebo odhadem budoucího pohybu cen akcií (Sezer a kol., 2019, str. 39)

Mezi další oblasti aplikace strojového učení patří také:

- Související s oceňováním jiných aktiv: komodity, dluhopisy, měnové kurzy a kryptoměny.
- Jiná finanční témata (Sellhorn, 2020): tvorba účetních odhadů, vyhodnocení kreditního rizika, detekce anomálií a odhad poptávky a nabídky. Protože tyto oblasti nespádají do mého zaměření na ocenění podniku, dále se jimi v tomto článku nebudu zabývat.

Akcie

Odhad budoucí ceny akcií patří snad mezi nejvíce zkoumané oblasti. (Sezer a kol., 2019, str. 17). Podle mého zjištění toto platí i o strojovém učení v oblasti financí podniku a jeho ocenění. Sezer a kol., 2019, str. 17, ukazují, že současný výzkum upřednostňuje spíše odhadování směru budoucího pohybu ceny (trend). Tento posun ve formulaci výzkumné otázky má vliv na metodologii strojového učení. Z technického pohledu se jedná o klasifikační úlohu (zjišťuje se, jestli cena poroste/klesne) místo regresní úlohy (hledá se kolik bude cena). Model i způsob vyhodnocení úspěšnosti se tedy bude lišit, ačkoliv z věcného hlediska je rozdíl spíše jen v interpretaci výsledků, neboť vysvětlovanou proměnnou ovlivňují stejné faktory (Sezer a kol., 2019, str. 32).

Ze zkoumaných studií vyplývá, že metodika se mezi články poměrně liší. Celkově lze učinit následující shrnutí:

- Vstupní data o tržních cenách akcií jsou z různě dlouhých období (obvykle 1 - 5 let nebo 15 - 25 let. Dle zjištění (Jiang, 2021, str. 16) souvisí volba délky období na frekvenci tržních dat (od vysokofrekvenčních denních až po měsíční data).
- Nejčastěji však jsem se setkala s denní frekvencí, a to obzvláště v novějších člancích (Jiang, 2021, str. 9).
- Data jsou za různý počet společností (obvykle desítky až stovky, ale objevují se i analýzy pro jednu nebo několik málo společností (viz Sezer a kol., 2019, str. 17-22), a to jak z rozvinutých trhů (především USA), tak i z rozvíjejících ekonomik (např. Čína) (Jiang, 2021, str. 10);
- Kromě tržních cen akcií se často v primárních studiích objevují i další vstupní data zahrnují například makroekonomická data, technické analýzy (i ve formě obrázků (viz Jiang, 2021, str. 13-14), fundamentální data, zprávy z Reuters a Bloombergu, příspěvky ze sociálních médií apod.
- Jiang, 2021, str. 20, zjistil, že nejčastěji se objevují čistě tržní ceny (36 % studií), následované kombinací tržních cen a technických indikátorů (25 %). Dle studie (Vachhani a kol., 2019) se pohybuje počet vysvětlujících proměnných v jednotlivých výzkumech kolem mediánu 6,5. Relativně nízký počet proměnných pravděpodobně ukazuje na riziko přeučení u ML, kterého se autoři studií snaží vyvarovat.

Akciové indexy

Predikce akciových indexů se ukazuje být rovněž relativně oblíbeným tématem. Výhoda použití akciových indexů (Sezer a kol., 2019, str. 23) ve výzkumu spočívá v tom, že jejich průběh je méně volatilní a více vypovídá o celkovém stavu ekonomiky. O analyzovaných výzkumech se dá obecně říci, že:

- nejčastěji jsou použita tržní data o akciovém indexu S&P500 a dále asijské indexy, např. Tokyo Nikkei Index (NIKKEI)225, The Korea Composite Stock Price Index (KOSPI), a Dow Jones Industrial Average (DJIA);
- obdobně jako u akcií, některé studie zahrnuly i dodatečné zdroje dat, se kterými jsou tržní data kombinována;
- horizont predikce opět převládá denní, ale častěji se objevují vícedenní (7 – 30 dní) u výzkumů zahrnující pouze vstupní data o akciovém indexu.

Ostatní typy aktiv

Relativně velkému zájmu (i když ve srovnání s akciemi výrazně menšímu) se těší predikce cen vybraných komodit (Sezer a kol., 2019, str. 27-28).

Díky vysoké likviditě trhu s měnami se také objevují výzkumy zahrnující predikce měnových kurzů, a to zpravidla v páru s USD, (Sezer a kol., 2019, str. 30). Nejčastěji se jedná

o jednodenní predikce (Sezer a kol., 2019, str. 29). Objevuje se také výzkum zaměřený na kryptoměny (zpravidla bitcoin). (Sezer a kol., 2019, str. 32).

Predikce cen dluhopisů zřejmě není obvyklá. Zmíněná byla pouze jedna studie (Sezer a kol., 2019, str. 28)

Může být strojové učení užitečné ve financích podniku a jeho ocenění?

Celkově se dá shrnout, že analyzované metastudie se většinou shodují, že strojové učení dosahuje v predikcích finančních časových řad nebývalé přesnosti. Zároveň lze také pozorovat, že používané modely jsou stále komplexnější (viz vývoj od jednodušších modelů jako SVM k neuronovým sítím až k hybridním modelům). Otázka je, jestli nejsou výzkumníci přehnaně optimističtí a jestli mají popisované modely šanci obstát v praxi.

Zajímavou diskuzi představil Buczynski a kol., 2021, str. 228-229. Namítají, že jestliže jsou ML algoritmy konzistentně schopné dosahovat predikční přesnosti nad 90 %, jak většinou tvrdí vědecké studie, pak by zákonitě i v investiční praxi mělo převládnout využití ML. Na základě jejich zjištění tomu tak není. Vychází přitom z informací o velikosti spravovaného majetku investory, kteří (deklarují, že) pro své rozhodování převážně využívají ML. Tuto hodnotu srovnává s hodnotou spravovaného majetku v celém odvětví investičního managementu (zjednodušeně jako 500 největších fondů). Uvedená čísla nechci přesně replikovat, protože sám autor přiznává, že vzhledem k obtížnosti získat spolehlivá data mu nejde o vyčíslení přesného podílu, ale o hrubou ilustraci toho, že se jedná skutečně o zanedbatelně malý podíl (na základě jejich údajů k roku 2017 méně než 1 %).

Osobně se domnívám, že pravda bude někdy mezi těmito dvěma póly: ML samo o sobě nebude schopno nahradit člověka v investičním rozhodování a ve financích podniku, ale určitě mu bude moci poskytnout zdroj dalšího pohledu na věc, který se může ukázat jako užitečný. Doporučuji téma využití strojového učení ve financích podniku a jeho ocenění dál sledovat.

Závěr

V tomto článku jsem se zabývala aplikacemi strojového učení ve financích, konkrétně pro finance podniku a jeho ocenění. Na základě rešerše současné literatury jsem se snažila poskytnout základní orientaci ve využití strojového učení ve financích podniku a jeho ocenění.

V rámci zvoleného tématu jsem pozorovala, že nejčastější oblastí aplikace v rámci financí je predikce budoucích cen aktiv, především akcií. Protože téma ocenění akcií je relevantní pro ekonomy působící v oblasti financí podniku a jeho oceňování, doporučuji vývoj v této oblasti dále sledovat. Vědecké výzkumy ukazují slibné výsledky, což prokazuje i velký počet nových článků na toto téma. Zdá se ale pravděpodobné, že na přechod z teorie do praxe ještě budeme muset čekat.

Literatura

- [1] Buczynski, W., Cuzzolin, F., a Sahakian, B. (2021): A review of machine learning experiments in equity investment decision-making: why most published research findings do not live up to their promise in real life. *International Journal of Data Science and Analytics* (11), P. 221-242. <https://doi.org/10.1007/s41060-021-00245-5>
- [2] Durairaj, M., & Mohan, B. K. (2019): A Review of Two Decades of Deep Learning Hybrids for Financial Time Series Prediction. *International Journal on Emerging Technologies*, 10(3), p. 324-331.
- [3] Ferreira, F. G., Gandomi, A. H., a Cardoso, R. T. (2021): Artificial intelligence applied to stock market trading: A review. *IEEE Access*, 9, 30898-30917.
- [4] Ghoddusi, H., Creamer, G. G. a Rafizadeh, N. (2019): Machine Learning in Energy Economics and Finance: A Review. *Energy Economics*, 81. Preprint. P 1-72 <https://doi.org/10.1016/j.eneco.2019.05.006>
- [5] Hastie, T., Tibshirani, R. and Friedman, J. (2001): *The Elements of Statistical Learning, Data Mining, Inference, and Prediction*. Springer, New York. ISBN 0-387-95284-5
- [6] Huang, J., Chai, J., a Cho, S. (2020): Deep learning in finance a banking: A literature review and classification. *Frontiers of Business Research in China*, 14:13, p. 1-24. <https://doi.org/10.1186/s11782-020-00082-6>
- [7] Jiang, W. (2021): Applications of deep learning in stock market prediction: recent progress. *Expert Systems with Applications*, 184: 115537. Preprint. P. 1-97. <https://doi.org/10.1016/j.eswa.2021.115537>
- [8] Kuizinienė, D., a Krilavičius, T. (2020): Deep learning methods application in finance: a review of state of art. In *CEUR Workshop proceedings [electronic resource]: IVUS 2020, Information society a university studies*, Kaunas, Lithuania, 23 April, 2020: proceedings. Aachen: CEUR-WS, 2020, Vol. 2698. p. 59-69.
- [9] Mueller, J. P., & Massaron, L. (2016): *Machine Learning for dummies*. John Wiley & Sons, New Jersey. P. 410. ISBN 978-1-119-24551-3
- [10] Müller, A. C., and Guido, S. (2016): *Introduction to Machine Learning with Python: A Guide for Data Scientists*, O'Reilly Media, Incorporated. ISBN 978-1-449-36941-5
- [11] Ozbayoglu, A. M., Gudelek, M. U., a Sezer, O. B. (2020): Deep learning for financial applications: A survey. *Applied Soft Computing*, 93, 106384. Preprint. P. 1-52. <https://doi.org/10.1016/j.asoc.2020.106384>
- [12] Rundo, F., Trenta, F., Luigi di Stallo, A. a Battiato, S. (2019): Machine Learning for Quantitative Finance Applications: A Survey. *Applied Sciences*, 9(24), 5574. p. 1-20. <https://doi.org/10.3390/app9245574>
- [13] Sellhorn, T., (2020): Machine Learning und empirische Rechnungslegungsforschung: Einige Erkenntnisse und offene Fragen. *Schmalenbachs Z betriebswirtsch Forsch* 72, 49–69. <https://doi.org/10.1007/s41471-020-00086-1>
- [14] Sezer, O. B., Gudelek, M. U., a Ozbayoglu, A. M. (2019): Financial time series forecasting with deep learning: A systematic literature review: 2005–2019. *Applied Soft Computing*, 90, 106181. p. 1-63. Preprint. arXiv preprint arXiv:1911.13288.

- [15] Shah, D., Isah, H., a Zulkernine, F. (2019): Stock market analysis: A review and taxonomy of prediction techniques. *International Journal of Financial Studies*, 7(2), 26. p. 1-21. <https://doi.org/10.3390/ijfs7020026>
- [16] Singh, N.P., Som, B.K., Komalavalli, C. a Goel, H. (2021): A Meta-Analysis of the Application of Artificial Neural Networks in Accounting a Finance. *SCMS Journal of Indian Management*, 18(1), pp. 5-21.
- [17] Vachhani, H., Obiadat, M. S., Thakkar, A., Shah, V., Sojitra, R., Bhatia, J., & Tanwar, S. (2019): Machine learning based stock market analysis: A short survey. In *International Conference on Innovative Data Communication Technologies a Application*. Springer, Cham. P. 12-26.
- [18] Warin, T. a Stojkov, A. (2021): Machine Learning in Finance: A Metadata-Based Systematic Review of the Literature. *Journal of Risk a Financial Management* 14, no. 7: 302. P. 1-31. <https://doi.org/10.3390/jrfm14070302>

Může být strojové učení užitečné ve financích podniku a jeho ocenění? Přehled současného výzkumu

Veronika Staňková

ABSTRAKT

Predikce finančních časových řad je v centru zájmu vědeckého výzkumu po dlouhou dobu. Nedávno se k tomu přidaly široké možnosti aplikovat metody strojového učení. V současné době se publikuje tak velké množství vědeckých článků v oblasti aplikace strojového učení ve financích, že je velmi obtížné se v nich zorientovat. Cíl tohoto článku je poskytnout základní přehled o tom, jaký je současný stav poznání v této oblasti, konkrétně pro finance podniku a jeho ocenění, a pomoci se zorientovat v metodách strojového učení těm, kteří se doposud strojovým učením nezabývali.

Klíčová slova: Strojové učení; Hluboké učení; Finance; Akcie.

Can Machine Learning Be Useful in Corporate Finance and Business Valuation? Overview of Current Research

ABSTRACT

Prediction of financial time series has been at the centre of scientific research for a long time. Recently, there have been a wide range of possibilities to apply machine learning methods. Currently, there are so many scientific papers in the field of application of machine learning in finance that it is very difficult to find the way around. The presented paper aims to provide a fundamental overview of the current state of knowledge in this area, specifically within the area of corporate finance and business valuation, and to assist in orientation in the methods of machine learning those who have not yet encountered machine learning.

Key words: Machine learning; Deep learning; Finance; Shares.

JEL classification: G120