



Posudek vedoucího bakalářské práce studenta **Ondřeje Šrámka**  
"Pokročilé architektury neuronových sítí pro analýzu dat z finančních trhů"

**Úvod.** Předkládaná práce se zabývá predikcí vývoje ceny kryptoměn na základě analýzy historických dat pomocí rekurentních neuronových sítí (NS), která má představovat jistou alternativu a zobecnění metod technické analýzy. Vzhledem k tomu, že jsem se dosud vědecky a převážně i pedagogicky pohyboval v oboru matematického modelování přírodních a průmyslových procesů, je pro mě jako školitele toto téma odvážným, provokativním a téměř drzým krokem do zdánlivě nesusouvisející a nevědecké oblasti. Přesto výzkum v daném směru považuji za relevantní a přínosný, například z následujících důvodů:

- Metody strojového učení a NS zažívají v posledních letech obrovský rozvoj a získat teoretické a implementační dovednosti v tomto oboru je pro studenty velmi cenné. Totéž platí pro nás jako vědce, neboť NS nacházejí čím dál širší uplatnění i v oblastech, kde se dříve uplatňovaly klasické matematické a fyzikální modely.
- Máme k dispozici hardware (superpočítač HELIOS s akcelerátory NVIDIA Tesla V100) a expertní znalosti, které umožňují jeho efektivní využití nejen pro vysoce výkonné vědecké výpočty, ale i pro trénování modelů hlubokých NS. V tomto ohledu zůstával potenciál tohoto systému dosud nevyužit.
- Predikce cen obchodovaných aktiv pomocí matematických modelů je relevantní vědecká disciplína.
- Trh s kryptoměnami je oproti např. akciovým trhům vhodný pro analýzu, neboť potřebná data jsou relativně snadno přístupná téměř v reálném čase. Navíc nebývá tolik ovlivněn fundamentálními vlivy.

**Shrnutí odvedené práce.** První kapitola shrnuje a demonstruje mechanismus návrhu a trénování neuronových sítí v kontextu obecnějších principů strojového učení. Základní koncepty (lineárně separovatelná data, formulace lineární regrese, řešení minimalizací ztrátové funkce, gradientní sestup atp.) demonstruje na názorných obrázcích. Pro čtenáře zajímavější se o strojové učení z teoretické stránky Ondřej vybral a i s přehledným důkazem uvedl dvě důležité věty, které ukazují 1) úspěšnost iteračního trénování perceptronu a 2) důležitost použití nelineárních přechodových funkcí ve vícevrstvé NS. Z mého pohledu je hodnotná i pečlivá formulace algoritmu zpětného šíření pro výpočet gradientu ve vícevrstvých sítích, neboť v literatuře je většinou algoritmus vyložen příliš schematicky a nedostatečně pro účely jeho implementace. Kapitola je zakončena popisem rekurentních a LSTM sítí, které jsou v literatuře považovány za vhodné pro zpracování dat ve formě časových řad. Druhá kapitola v souladu se zadáním věnuje přetrénování (přeučení) a metodám, jak mu předejít.

Praktická část je náplní třetí kapitoly. Popisuje proces předzpracování dat zachycujících cenový vývoj Bitcoinu vůči USD pomocí Bollingerových indikátorů používaných v technické analýze. Jako

cílový problém byla zvolena klasifikace budoucího vývoje ceny na základě historických dat do tříd "růst", "stagnace" a "pokles". Je porovnáváno několik variant NS obsahujících LSTM vrstvy a další prvky potenciálně vylepšující trénování nebo omezující přeučení, jako je dropout nebo dávková normalizace. Úspěšnost predikce je vyhodnocována primárně pomocí matice záměn.

**Hodnocení a závěr.** Ondřej je schopný programátor, který se samostatně orientoval v dostupných technologiích. Využil nejen doporučené knihovny Keras a TensorFlow, nýbrž i další vhodné nástroje v ekosystému Pythonu, jako je Pandas, scikit-learn atd.). Navíc práci začínal se zkušeností v programátorské soutěži ("hackathonu"), jejímž cílem byla aplikace metod strojového učení. Proto mě trochu překvapilo, že při návrhu modelů a a vyhodnocování jejich úspěšnosti byl zpočátku poněkud bezradný - neuvědomoval si například, že grafy, které demonstrovaly zdánlivě vynikající úspěšnost predikce, neměly ve skutečnosti žádnou vypovídací hodnotu. To však demonstruje, jak důležitá je zkušenost s návrhem modelů NS a tedy i přínos práce na tématu.

Výsledky praktické části jsou očekávané – žádný z modelů (zatím) není ani zdaleka schopen predikovat změnu ceny v budoucnu tak, aby byl využitelný ve strategiích automatického obchodování. Trochu mě mrzelo, že jsme se nedostali dál a nevyzkoušeli např. jiný způsob předzpracování dat (Bollingerovy plovoucí průměry lze např., alespoň teoreticky, nahradit a zobecnit použitím konvoluční vrstvy NS). Diskutovali jsme spolu řadu nápadů a měl jsem pocit, že by Ondřej bez problémů zvládl implementovat i simulátor obchodování na základě predikcí z NS, k čemuž však nakonec rovněž nedošlo.

Z hlediska kvality textu měla práce na tématu naopak jednoznačně vzestupnou tendenci. První verze rešerše o NS trpěly mnoha věcnými i formálními nedostatky, ale naše časté konzultace a Ondřejova snaha vedly k radikálnímu zlepšení kvality textu. Ondřej také vytvořil řadu názorných a vizuálně kvalitních obrázků a koncepty použité v textu dokumentuje i úryvky zdrojového kódu. Přesto v textu stále zůstaly některé překlepy a další nedokonalosti.

K výše uvedenému hodnocení je třeba přidat ještě lidský rozměr, kdy během náročného období lockdownů veškerá spolupráce probíhala online a studenti byli při plnění studijních povinností doslova připoutáni k počítači od rána do večera. Navzdory tomu jsme udrželi pravidelnost konzultací, Ondřej neztratil motivaci a práci dovedl s mou pomocí do zdárného konce. Proto ji s radostí doporučuji k obhajobě a navrhuji nejvyšší hodnocení, tedy známku

**A (výborně).**

Praha 14. srpna 2021

Ing. Pavel Strachota, Ph.D.

---

**Ing. Pavel Strachota, Ph.D.**

katedra matematiky  
Fakulta jaderná a fyzikálně inženýrská  
České vysoké učení technické v Praze  
Trojanova 13  
120 00 Praha 2

Tel: (+420) 224 358 563

E-mail: pavel.strachota@fjfi.cvut.cz