

Algoritmické obchodování na burze s využitím umělých neuronových sítí

Karel Červíček

Abstrakt

Forex je dnes největším devizovým trhem s velkou komunitou obchodníků, kteří obchodují intraday manuálně, ale také je zde velký potenciál pro automatické obchodování. V tomto článku je využit model dopředné umělé neuronové sítě jako logistické regrese. Neuronová síť je vhodným matematickým modelem pro generalizaci funkce měnového páru, pokud je pro trénování použit správný formát dat. Pro ziskový algoritmus je tedy třeba se zaměřit na vhodnou topologii sítě, vhodný výběr dat pro trénování a návrh logiky pro vstup do obchodní pozice, to vše je zde řešeno.

Klíčová slova: neuronové sítě - machine learnig - forex - automatické obchodování - burza - predikce časové řady

Příložené materiály: N/A

*xcervi19@fit.vutbr.cz, Faculty of Information Technology, Brno University of Technology

1. Úvod

Podstatou této práce je využití neuronové sítě pro vytvoření obchodního algoritmu. Ke splnění tohoto bodu je zásadní pochopit princip forexu, čili obchodování na měnových trzích. S tím je spojeno mnoho dalších věcí například různé principy obchodních strategií. Ty jsou rozděleny do dvou hlavních skupin, a to technická a fundamentální analýza. Dále je také nutné použít správný formát dat pro trénink neuronové sítě, a proto je také nutné pochopit jejich princip. Zde nebude přímo řešeno, jak neuronová síť funguje z hlediska celkového konceptu. Na základě testů je zde ukázáno, že určité přístupy, které jsou v některých oblastech velice efektivní, zde selhávají. Příčinou je různé rozložení pravděpodobnosti kurzovních dat predikovaného signálu, a to u časové řady signálu měnového páru činí zásadní problém. Také je nutné poznamenat, že signál burzy je celkově velmi těžko predikovatelný. Díky těmto poznatkům bude postaven obchodní algoritmus, který bude predikovat budoucí trend trhu na základě technické analýzy, která je základem pro predikci.

Výsledný obchodní model řeší problém generalizace šumu využitím klouzavých průměrů a data jsou transformována tak, aby je bylo možné dobře generali-

zovat pomocí vícevrstvé dopředné neuronové sítě. Na základě predikce je vytvořena rozhodovací logika pro otevírání obchodních pozic.

2. Forex

Článek se zabývá pouze obchodováním na Forexu. Forex je zkratka pro Foreign Exchange.

Jde o mezinárodní devizový trh, kde jsou prováděny směny hlavních a vedlejších měnových párů. Důvodem výběru tohoto trhu je možnost

24 hodinového obchodování kromě víkendů a také fakt, že Forex je největším trhem na světě [1] i přes to, že Forex nemá vlastní burzu a směny jsou prováděny v rámci mezibankovních transakcí. Zde uvedu jen podstatné informace, které se týkají praktické části 7.

V tomto článku pracuji s párem EUR/USD (euro/americký dolar). Co to jsou páry a jakou hrají roli je možné se dozvědět zde [2].

Také je nutné uvést charakter dat, se kterým pracuji v praktické části 7. Na obrázku 1 je vidět svíčkový graf, který zobrazuje kurzovní data. Každá svíce se uzavře za jistý timeframe [2] a skládá se z 5 hodnot close, high, high, low a volume, co jednotlivé hodnoty znamenají je možné zjistit zde [1]. V praktické části pracuji pouze s hodnotou close v rozmezí jedné minuty



Obrázek 1. Ukázka grafu měnového páru s klouzavými průměry, jako obchodní strategií. Zdroj: internet

(timeframe jedna minuta). Není jednoduché získat historická data. K získání dostatečného množství dat jsem využil program `tickstory`¹

Obchodní model v praktické části je postaven tak, aby zastínil co nejvíce problému při obchodování u brokera, nastavením pozice a časovým intervalem, kdy jsme v obchodní pozici. Uvod do této problematiky je možné nastudovat z knihy [1] a nebo zde [2].

3. Technické indikátory

Technická analýza se využívá k předpovídání budoucích cenových pohybů na základě hodnot tvořené trhem. Na rozdíl od fundamentální analýzy, která zkoumá jevy jako jsou zveřejnění ekonomických dat, ekonomická situace států nebo politická situace. V technické analýze jsou využívány technické indikátory a jedním z nich je klouzavý průměr, který je využíván v praktické části 7. Bližší informace o technické analýze je možné zjistit zde [3].

3.1 Klouzavý průměr

Klouzavý průměr je zásadní indikátor v technické analýze a uvádím jej, neboť jeho varianty jsou využity v obchodním modelu této práce. Je používán pro detekci trendu časové řady a proto je pro obchodní model důležitý. Jednoduchý Klouzavý průměr je počítán takto:

$$MA = \frac{1}{n} \sum_{i=1}^n P_{m-i} \quad (1)$$

V praktické části je také využíván *EMA* (exponenciální klouzavý průměr). *WMA* (vážený klouzavý průměr) a *KAMA* (Kaufman's Adaptive Moving Average).

4. Studie využití neuronových sítí

Neuronové sítě jsou vhodným matematickým modelem pro nelineární klasifikaci a predikci. V článku [4] predikují sekundární struktury proteinu, nebo je také

možné odhadovat možné sesuvy půdy [5]. Na řešení predikce budoucího kurzu je možné využít dopřednou vícevrstvou neuronovou síť a algoritmus zpětné propagace, ale je zde problém s generalizací šumu při trénování [6]. Dále je vhodnější využití klouzavých průměrů než přímo daných cen (v našem případě kurzovních hodnot páru EUR/USD) [6]. Také podle článku [7] je možné využít logaritmickou diferenci pro zlepšení generalizace.

$$d = \ln \frac{P_t}{P_{t-1}} \quad (2)$$

Kde P_t je cena v čase t a P_{t-1} cena v čase $t - 1$. Důvod proč tato transformace a její obdoby fungují, je vysvětlen v sekci 7.1 na základě [8].

5. Standardní zpětná propagace

Vysvětlení tohoto algoritmu bude pomocí jednoduchého vícevrstvého modelu založeného na učení z gradientu. Každá vrstva je definována funkcí $F_n(W_n, X_{n-1})$. X_n je výstupem každé vrstvy a X_{n-1} je vstupem. W je vektorem vah, který je ovlivnitelný, což bude hrát v tomto algoritmu zásadní roli. Z^i je vstupním vzorkem dat a je ekvivalentem X_0 . Tím je dáno, že je známa parciální derivace funkce E^p podle proměnné X_n . A pokud je možné spočítat parciální derivaci funkce E^p podle W_n , pomocí Diferenčních rovnic je potom možné spočítat X_{n-1} .

$$\frac{\partial E^p}{\partial W_n} = \frac{\partial F_n}{\partial W} (W_n, X_{n-1}) \frac{\partial E^p}{\partial X_n} \quad (3)$$

$$\frac{\partial E^p}{\partial X_{n-1}} = \frac{\partial F_n}{\partial X} (W_n, X_{n-1}) \frac{\partial E^p}{\partial X_n} \quad (4)$$

Kde $\frac{\partial F_n}{\partial X}$ je Jakobian W podle proměnné W v bodě daném $((W_n, X_{n-1}))$ a $\frac{\partial F_n}{\partial X}$ je Jakobian podle proměnné X . Jakobian vektorové funkce obsahuje parciální derivace všech výstupů s ohledem ke všem vstupům. Pokud tento výpočet provedeme pro každou vrstvu reverzně pro chybovou funkci, budou spočítány všechny parciální derivace s ohledem na všechny parametry. Speciálním případem tohoto systému je neuronová síť. Dále jsem vybral konkrétní příklad.

¹Pro stažení historických dat je možné využít: <https://tickstory.com/>

6. Praktiky trénování

Vzhledem k předchozí sekci je zřejmé, že hledání minima nebude jednoduché. Při topologii sítě, která bude reálně využitelná pro vytvoření obchodní strategie se budeme pohybovat v N-dimenzionálním prostoru s mnoha lokálními minimy. K nalezení optimálního minima je nutné pro trénování znát mnoho teoretických praktik, některé z nich zde rekapituluji.

6.1 Náhodné promíchání trénovací sady

Trénink neuronové sítě je efektivní, pokud jsou data na vstupu co nejvíce rozdílná. Neuronová síť by měla co nejvíce generalizovat a pokud bychom bezprostředně za sebou trénovali data podobná, tak se gradient ustanoví nepřesně a síť se celkově nenaučí v podstatě nic. Ovšem je těžké stanovit, která data jsou podobná a která ne. Proto je vhodným přístupem data náhodně zamíchat před procesem trénování. Také je možné v průběhu trénování opakovat proces u dat, které vykazovaly na výstupu velkou chybu. Tato technika je vhodná, ale v této práci neuplatněná, neboť je riziková z hlediska přetrénování na těchto datech.

6.2 Transformace vstupu

Tato část je z hlediska mé práce zásadní. Zde uvedu obecný pohled na problematiku obecných postupů, které je nutné udělat pro úspěšný trénink. Jako první bych uvedl normalizaci dat. Vstupem pro trénování i pro referenční data by měla být data s nulovou střední hodnotou a jednotkovou variancí. Tento přístup je vhodný pokud data mají normální rozložení, jak je dále vysvětleno. Pokud by data neměla nulovou střední hodnotu a byla například posunutá do kladných hodnot, pak by proces trénování byl zpomalen. Důvodem je, že váhy by byly ovlivněny pouze stejným znaménkem. Normalizaci je možné provést například podle tohoto vzorce:

$$X_i = \frac{X_i - \min(X)}{\max(X) - \min(X)} \quad (5)$$


Nebo:

$$X_i = \frac{X_i - \bar{X}}{\sigma} \quad (6)$$

Vzhledem k problémům s rozložením pravděpodobnosti časové řady měnového páru je v praktické části provedeno pouze odečtení průměru a každá hodnota je vynásobena konstantou pro zachování variance

$$X_i = (X_i - \bar{X}) * k \quad (7)$$

Konstanta k je zvolena tak, aby data byla v rozmezí $(-1, 1)$.



Obrázek 2. Funkce tanh, která je využita jako aktivační funkce. Zdroj: https://help.scilab.org/docs/5.5.2/en_US/tanh_1.png

6.3 Aktivační funkce

Hlavním prvkem, který dává neuronové síti možnost klasifikovat nelineární problémy, je nelineární aktivační funkce. Nejvíce užívané jsou dvě základní: sigmoida

$$X_i = \frac{1}{1 + e^{-x}} \quad (8)$$

a $\tanh$:

$$X_i = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (9)$$

S odkazem na normalizaci je vhodné používat $\tanh$, neboť jak je vidět na obrázku 2, rozsah oboru hodnot funkce $\tanh$ je mezi $-1,1$ na rozdíl od funkce sigmoid, která je pouze v kladných hodnotách. To jaká aktivační funkce je vhodná se odvíjí od charakteru dat, se kterými pracujeme.

Teorie také poukazuje na fakt, že obě funkce a to zejména sigmoida se drží v plochých zónách a učení je tím zpomalen. Proto je možné využít také upravené funkce: $f(x) = 1.7159 \tanh(\frac{2}{3}x)$ [9]. Hlavní výhodou je že funkční hodnota v 1 je 1. Toto je opět spjato s normalizací dat. Díky tomuto rozsahu je první derivace větší v intervalu $(-1, 1)$.

7. Praktické poznatky a ziskový algoritmus

7.1 Rozložení pravděpodobnosti dat burzy

Důležitým poznatkem je, že rozložení pravděpodobnosti signálu **eur/usd** není normální [8]. V kapitole 6.2 je psáno, že normalizace je nutná, ale není možné data transformovat tak, aby měla varianci jedna. V praktických testech jsem testoval různé přístupy normalizace a v testech, kde jsem měnil celkovou varianci dat, byly výsledky nejhorší. Ověřil jsem, že data nemají normální rozložení.

Podle zdroje [8] je možné uvažovat rozložení, které je podobné rozložení exponenciálnímu. Zde není aktivována centrální limitní věta, která u normálního rozložení splněna je.

Centrální limitní věta 1. *Nechť $\bar{X}$ je průměr náhodného výběru z rozdělení se střední hodnotou μ a rozptylem $\sigma > 0$. Pak*

$$W = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \quad (10)$$

má rozdělení $N(0, 1)$ pro $n \Rightarrow \infty$.

Aplikace: Pokud je n dost velké, pak:

$$W = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} = \frac{\frac{1}{n} \sum \bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} = \frac{\frac{1}{n} \sum \bar{X} - \mu * n}{n * \frac{\sigma}{\sqrt{n}}} = \frac{\sum \bar{X}_i - \mu * n}{\sqrt{n} * \sigma} \quad (11)$$

má přibližně standardní normální rozložení $N(0, 1)$.

Centrální limitní věta říká, že pokud náhodná veličina V z daného výběru může být vyjádřena jako součet náhodných proměnných složených z variancí, tak distribuce V je přibližně normální.

Při vyřešení tohoto problému, čili vytvoření dat, které budou v normálním rozložení a budou splňovat centrální limitní větu, budou výsledky predikce znatelně lepší.

7.2 Rozložení pravděpodobnosti dat burzy

Možností, která vedla k nejlepším výsledkům, bylo vytvoření rozdílu jednotlivých cen, čili se jedná o časovou řadu diferencí dvou cen. Tato data jsou pro trénování vhodná, ale s tímto přístupem je třeba redukovat šum signálu.

7.3 Možnost redukce náhodného šumu

Při testech obchodního algoritmu hrál náhodný šum zásadní roli a silně ovlivňoval výstupní data neuronové sítě. V tomto případě, kdy využívám neuronovou síť jako obecný aproximátor, velmi často docházelo k problémům, kdy příliš velká variance predikci naprosto znehodnotila. Z tohoto důvodu jsem testoval několik možností, jak redukovat náhodný šum a zvýraznit hlavní trend.

7.4 Využití klouzavých průměrů

Je možné využít klouzavých průměrů. Vhodnou volbou několika klouzavých průměrů zredukuji šum. Také je zde zásadní výhoda, že je zachována celková variance a nejsou brána v potaz data z budoucnosti. Pro zachování důležitých složek signálu je nutné použít co nejvíce klouzavých průměrů. Dále bude ukázáno, že pokud by byl použit pouze klasický moving average výsledky nebudou dobré, jako při využití $MA, EMA, WMA, KAMA$ a dalších na 11 000 testovacích datech. Jedná se o

7.5 Konečný návrh obchodního algoritmu

Po testování byl sestaven konečný obchodní algoritmus, který je ziskový. Po 34 testech, kdy bylo kombinováno několik technických indikátorů, jsem došel k nejlepším výsledkům při modelu, který bude následně popsán.

V první řadě jsem sestavil matici klouzavých průměrů. Základní myšlenkou je predikce první derivace časové řady. Přesněji v tomto případě budu predikovat první derivaci moving average. Ještě přesněji je pro každý časový úsek spočítána lineární regrese pro následujících patnáct hodnot. A směrnice této přímky je brána jako první derivace v daném bodě, což znamená, že je možné uvažovat v rámci patnácti minut, neboť v tomto případě bude obchodováno v jednominutovém timeframu.

Dále také aplikuji poznatky popsané dříve pro eliminaci problémů s aktivací centrální limitní věty. Dále jsem zjistil, že je také nutné neuronovou síť stále trénovat s daty, kde je zachována hodnota ceny v tom samém poměru jako v referenčním signálu. Na vstupu neuronové sítě je tedy spojený vektor diferencí klouzavých průměrů a také hodnot samotných. Diference je počítána takto:

$$D_{ma} = MA_n - MA_{n-1} \quad (12)$$

$$D_{ema} = EMA_n - EMA_{n-1} \quad (13)$$

$$D_{wma} = WMA_n - WMA_{n-1} \quad (14)$$

$$D_{kama} = KAMA_n - KAMA_{n-1} \quad (15)$$


Dále je spočítána první derivace klasického moving average, která je predikována, čili je na výstupu neuronové sítě. Pro upřesnění představy, jak jsou data na vstupu neuronové sítě uspořádány, je možné se podívat na obrázek 3.

Tento přístup je vhodný zejména proto, že na výstupu neuronové sítě je pouze jedna hodnota a trénování neuronové sítě je jednodušší. Také máme jasnou představu o tom, jaký bude trend.

7.5.1 Logika řízení obchodních pozic

Vstup a výstup z pozice bude usuzován na základě velikosti směrnice v daném bodě. Pokud bude směrnice větší než nastavená hodnota, bude nastavena pozice long, pokud již nastavena není. Opakem bude případ nastavení pozice short. Pokud bude hodnota směrnice menší než záporná hodnota prahu, tak bude pozice short nastavena.

Po natrénování neuronové sítě na datech o délce 603 189 (hodnoty close páru **EUR/USD**) jsem provedl ~~KAMA~~ **KAMA** a dalších na 11 000 testovacích datech. Jedná se o pár **eur/usd**. Výběr toho to páru je přímočarý, neboť



Obrázek 3. Formát dat pro trénink neuronové sítě a následnou predikci směrnice na základě aktuálních hodnot klouzavých průměrů

jde o nejobchodovanější pár na forexu a je velmi stabilní. Jde nám o dlouhodobé obchody bez ukončování, abychom na spreadu zaplatili co nejméně. Proto je pozice ukončena až s nástupem další pozice a pokud je možnost otevřít například pozici long v době, kdy už v long jsme, tak nová pozice není otevřena. Toto je vysvětleno v pseudokódu 1.

```
threshold = 0.4
in_position = False
Output:  $X_t$ 
while derivativei not null do
  if derivativei > threshold then
    if in_position == False then
      set long position
      unset short position
      in_position = True
    end
  end
  if derivativei < threshold * -1 then
    if in_position == False then
      unset long position
      set short position
      in_position = True
    end
  end
end
```

Algoritmus 1: position set

7.5.2 Evaluace predikce

V oboru strojového učení je rozhodující správné zhodnocení hodnot, které po natrénování obdržíme, v tomto případě zhodnocení predikce. Zde připadá v úvahu vhodná vizualizace dat, funkce pro vyhodnocení chyby

predikce a sestavení algoritmu, který bude predikci hodnotit s ohledem na daný problém. Zde je mnoho problémů, například v této práci jsou nejvíce řešeny vlivy vysoké variance, které silně ovlivní výstup, pak také zpoždění predikce. To vše je nutné vhodně zhodnotit a vzhledem k tomu, že predikce signálu burzy je díky chaotickému charakteru dat velmi náročná a podstatou celé práce je ziskový obchodní algoritmus, usoudil jsem, že nejvhodnější bude evaluace zisku, tak jak je uvedeno v předchozí kapitole 7.5.1.


Vše je vidět na obrázku 6, kde jsou vyznačené zobchodované pozice. Díky tomu, že jde o zobrazení pouze 100 hodnot, je zde dobře vidět, jak variance vstupních dat ovlivňuje predikci. Také je velmi dobře vidět, kde je překročen práh a proč je nutné otevřít pouze jednu pozici.

Dalším vyhodnocením je jednak samotná chyba na konci poslední epochy, ale v tomto případě hlavně hraje roli poměr chyby a počtu epoch. Zvolil jsem trénování, které je zastaveno dynamicky na základě změny chyby na datech pro validaci a díky tomu je dobře vidět zda neuronová síť má co generalizovat, čili pokud proběhne hodně epoch a chyba se bude stále zmenšovat, tak jdou data dobře generalizovat. Toto je demonstrováno v praktických testech 8.1.

Jako poslední uvedu ještě jeden způsob vyhodnocení predikce. Pokud hodnota na výstupu neuronové sítě určuje směrnici trendu v dalších 15 minutách, je vhodné zhodnotit zda za 15 minut dojde ke správné predikci. S každou predikovanou hodnotou je vyhodnocen rozdíl M_t a M_{t-15} , kde M je hodnota klouzavého průměru, ze kterého je počítána první derivace. Dále je také vyhodnocen rozdíl P_t a P_{t-15} , kde P je kurzovní hodnota páru EUR/USD. Tyto rozdíly jsou vyhodnoceny relativně k tomu, zda směrnice naznačuje růst nebo pokles, pokud je rozdíl kladný je přičten k celkovému růstu. Na obrázku 4 je možné vidět vyhodnocení predikce růstu, kde modrá funkce vypovídá o kvalitě predikce samotného klouzavého průměru a zelená funkce ukazuje kvalitu predikce růstu samotné ceny P . Na této ukázce je vidět, že predikce neuronové sítě je kvalitní, ovšem klouzavý průměr je zpožděný oproti samotné ceně.

7.5.3 Topologie sítě

V mnoha případech je topologie sítě zásadní, v počátku testů jsem se zaměřoval právě na topologii a různé nastavení hodnoty *learning rate*. Různé změny však nebyly zásadní zejména z důvodů, které jsou popsány výše. Pro objasnění zde uvedu, že konečný *learning rate* byl nastaven na 0.08 a topologie sítě je tvořena ze vstupní vrstvy, kde je velikost rovna velikosti trénovacího vektoru, dále jedna skrytá vrstva o stejné velikosti



Obrázek 4. modrá funkce ukazuje kvalitu predikce růstu klouzavého průměru po 15 minutách a zelená kvalitu predikce růstu pro samotnou cenu na základě predikce první derivace klouzavého průměru

jako vstupní a výstupní vrstva má pouze jeden neuron. Závěrem je přidáno zobrazení 10 000 hodnot

Tabulka 1. Tabulka testů pro výběr topologie

learnig rate	počet vrstev	konečná chyba
0.08	3	loss: 0.0127
0.08	2	loss: 0.0132
0.1	2	loss: 0.0214
0.08	4	loss: 0.0143

jako obrázek 5, kde jsou barevně označeny obchodní zóny. Červenou barvou jsou vyznačeny long pozice a světle modrou jsou pozice short. Spodní část grafu je věnována predikované směrnici, která určuje budoucí trend. Pro objasnění tam, kde je směrnice nulová, půjde trend do strany. Jde tedy o myšlenku, kdy vstoupíme do obchodu, pokud očekáváme jasné otočení trhu a pokud není predikován silný obrat, tak vše běží dál. Zisk v testech byl kladný a činil 2691 bodů. Dále také uvádím chybu po provedení první a poslední epochy:

8. Praktické testy s ohledem na hlavní algoritmus

V této části jsou ukázány testy, které vedly k výsledkům z části 7.5. Jsou zde demonstrovány problémy, o kterých je tento článek především a také je zde im-

Tabulka 2. Tabulka výsledků

Epocha	čas trénování	chyba
Epoch 1/200	18s	loss: 0.0758
Epoch 16/200	16s	loss: 0.0127
Zisk		
2641 bodů		

plicitně vidět proč jsem zavrhl například přidávání dalších indikátorů.

8.1 Vyloučení diferencí

Tento test je nejdůležitější, proto bude uveden jako první. Zde jsem vynechal difference klouzavých průměrů, čili data pro trénování rozhodně neměla normální rozložení a zde bude vidět, že neuronová síť nebude schopná správně funkci generalizovat, pokud nesplníme tuto důležitou podmínku. Dalším důležitým bodem je tedy normalizace, ta je však ponechána správně. Potom co na vstupu neuronové sítě byly pouze hodnoty klouzavých průměrů, probíhal trénink takto 3:

Tabulka 3. Tabulka výsledků

Epocha	čas trénování	chyba
Epoch 1/200	10s	loss: 0.0733
Epoch 9/200	8s	loss: 0.0244
Zisk		
0 bodů		

Z tabulky 3 je vidět znatelně méně provedených epoch o proti nasazené strategii 2 a to je přesný případ toho, o čem bylo psáno 7.5.2. Také jsem přidal obrázek 7 pro pochopení co se stalo. Z obrázku je jasné vidět, že síť negeneralizovala skoro žádnou varianci a co se týče odchylky, ta je uspokojivá jen díky tomu, že hodnoty signálu první derivace jsou blízko nuly.

8.2 Pouze difference

Dále bych chtěl ukázat i test, kdy jsem provedl trénování pouze s diferencí klouzavých průměrů a také to, že zde už neuronová síť je schopná funkci generalizovat a je schopna ziskových obchodů. Na počtu epoch a poklesu chyby je vidět, že tento přístup je správný. Zde také stále zachovávám normalizaci podle 6.2

I přes to, že chyba je menší než v hlavní strategii, která je vybrána pro obchod jsou zisky menší a to 1211 4. Důvodem je, že data jsou pro neuronovou síť zásadní a jejich rozložení pravděpodobnosti je lepší než pouze hodnoty klouzavých průměrů, ale v predikovaných datech byl znatelný šum (jak je vidět na obrázku

Tabulka 4. Tabulka výsledků

Epocha	čas trénování	chyba
Epoch 1/200	10s	loss: 0.0183
Epoch 37/200	8s	loss: 0.0118
Zisk		
1211 bodů		

8), který jsem eliminoval tím, že jsem vytvořil již prezentovanou strategii.

8.3 Přidání RSI

Při dalším testu jsem ponechal hlavní ziskovou strategii a k vektoru na vstupu jsem přidal technický indikátor *RSI*. Ten je pro trénování vhodný proto, že jeho hodnoty jsou stále ve stejném rozmezí a je možné jej velice dobře normalizovat. Výsledky však nebyly s větším ziskem než u hlavní strategie a to 754 bodů. Také zde uvedu průběh trénování a konečnou chybu 5:

Tabulka 5. Tabulka výsledků

Epocha	čas trénování	chyba
Epoch 1/200	10s	loss: 0.0675
Epoch 14/200	8s	loss: 0.0124
Zisk		
754 bodů		

9. Závěr


Závěrem bych chtěl shrnout celkové poznatky. Tato práce je základem pro další postup, neboť jsou zde popsány poznatky o tom, jak transformovat data signálu burzy, tak aby trénování neuronové sítě konvergovalo k dobrým výsledkům. Ověření těchto poznatků bylo provedeno prakticky a to vytvořením ziskového obchodního algoritmu s využitím neuronové sítě, který byl ziskový.

10. Acknowledgements


Srdečně bych chtěl poděkovat svému vedoucímu, kterým je Ing. Igor Szőke, Ph.D. Vděčím mu za cenné rady z oblasti trénování neuronové sítě.

Literatura


- [1] Lien Kathy. *FOREX – Ziskové intradenní a swingové obchodní strategie*. FXstreet.cz s.r.o., 2011. ISBN: 978-80-904418-2-8.
- [2] MICHAEL J. SHARPE. Forex walkthrough. INVESTOPEDIA, LLC. Investopedia [online]. 2010 [cit. 2015-03-26]. <http://www.investopedia.com/walkthrough/forex/>.
- [3] Boris Schlossberg. *Technical Analysis of the Currency Market: Classic Techniques for Profiting from Market Swings and Trader Sentiment*. Wiley, 2006. ISBN: 978-0471745938.
- [4] PATEL, Maulika S., and S. MAZUMDAR Himanshu. Knowledge base and neural network approach for protein secondary structure prediction. *Journal of Theoretical Biology* [online]. <http://www.sciencedirect.com/science/article/pii/S0022519314004536>.
- [5] Cheng LIAN, ZENGv Zhigang, Wei YAO, and Huiming TANG. Multiple neural networks switched prediction for landslide displacement. *Engineering Geology* [online]. <http://www.sciencedirect.com/science/article/pii/S0013795214003202>.
- [6] YAO, Jingtao, and Chew Lim TAN. A case study on using neural networks to perform technical forecasting of forex. *Neurocomputing*. 2000, vol. 34, 1-4, s. 79-98. DOI: 10.1016/S0925-2312(00)00300-3. <http://www.sciencedirect.com/science/article/pii/S0925231200003003>.
- [7] EVANS, Cain, Konstantinos PAPPAS, and Fatos XHAFIA. Utilizing artificial neural networks and genetic algorithms to build an algo-trading model for intra-day foreign exchange speculation. *Mathematical and Computer Modelling*. <http://www.sciencedirect.com/science/article/pii/S0895717713000290>.
- [8] MICHAEL J. SHARPE. Lognormal model for stock prices. MATHEMATICS DEPARTMENT, UCSD. <http://math.ucsd.edu/~msharpe/stockgrowth.pdf>.
- [9] LeCun Yann, Bottou Leon, B. Orr Genevieve, and Muller Klaus-Robert. Efficient backprop, Dec 1998. <http://yann.lecun.com/exdb/publis/pdf/lecun-98b.pdf>.




Obrázek 5. Ukázka obchodů, kde v horní části je realná cena a dole první derivace MA, predikovaná neuronovou sítí. Červeně jsou potom long pozice (buy) a modře short pozice (sell).



Obrázek 6. V horní části je referenční signál a v dolní první derivace signálu v porovnání s predikcí derivace, která má primárně zelenou barvu. Přímky značí zobchodované zóny.



Obrázek 7. Ukázka výsledků predikce pro natrénování dat bez diferencí



Obrázek 8. Ukázka výsledků predikce pro natrénování dat pouze diferencí klouzavých průměrů