

Prognozowanie kursu bitcoina z wykorzystaniem sztucznej sieci neuronowej

Artur Paździor, Grzegorz Kłosowski*

Streszczenie: *Cel* – Celem artykułu jest prezentacja koncepcji systemu informatycznego umożliwiającego prognozowanie kursu kryptowaluty bitcoin (BTC) w odniesieniu do waluty euro.

Metodologia badania – Na potrzeby realizacji tak sformułowanego celu opracowano model sztucznej sieci neuronowej – perceptronu wielowarstwowego. W ramach badań dobrano zmienne wejściowe, od których uzależniono kurs BTC. Pozyskano także odpowiednie dane, pochodzące z dziennych notowań kursów wybranych walut i metali. Dane poddano stosownej obróbce matematycznej w celu ich dostosowania do wykorzystania podczas uczenia, walidacji i testowania sztucznej sieci neuronowej.

Oryginalność/wartość – Oryginalny był dobór wektora zmiennych wejściowych, umożliwiających prognozowanie kursu BTC. Wyniki przeprowadzonych eksperymentów potwierdziły wysoką skuteczność prognozowania w perspektywie jedno- i dwudniowej. Wysokie wartości współczynnika regresji (R) i mały błąd średniokwadratowy (MSE) świadczą o tym, że opracowany system predykcyjny prawidłowo przewiduje kursy analizowanej kryptowaluty nie tylko w odniesieniu do danych historycznych, lecz także dla wartości bieżących i przyszłych.

Słowa kluczowe: rynek kapitałowy, kryptowaluty, prognozowanie zmian kursów, sztuczna sieć neuronowa

Wprowadzenie

Struktura, charakter, specyfika funkcjonowania, rodzaj instrumentów oraz rodzaje analiz wykorzystywanych w procesach inwestycyjnych na rynku finansowym w ostatnich dekadach uległy znaczącym przeobrażeniom. Jeszcze na przełomie XX i XXI wieku wydawało się, że wektor zmian na światowych rynkach finansowych jest klarowny i zmierza w kierunku popularyzacji instrumentów pochodnych (derywatów)¹. Na popularyzację instrumentów pochodnych nie miały wpływu także zjawisko globalizacji rynków finansowych, które doprowadziło do znacznego wzrostu wolumenu i dywersyfikacji transakcji finansowych (Stankovska,

* dr hab. inż. Artur Paździor prof. PL, Politechnika Lubelska, Wydział Zarządzania, Katedra Finansów i Rachunkowości, e-mail: a.pazdzior@pollub.pl; dr inż. Grzegorz Kłosowski, Politechnika Lubelska, Wydział Zarządzania, Katedra Organizacji Przedsiębiorstwa, e-mail: g.klosowski@pollub.pl.

¹ Rynek terminowy w Polsce upowszechnił się w drugiej połowie lat 90. XX wieku, kiedy to 16 stycznia 1998 r. po raz pierwszy uruchomiono rynek terminowy poprzez wprowadzenie do obrotu kontraktów terminowych na indeks WIG20. Obecnie (wg stanu na 10.09.2018 r.) na Gieldzie Papierów Wartościowych w Warszawie notowane są zarówno kontrakty terminowe (indeksowe, akcyjne, walutowe, obligacyjne, na stopy procentowe), jak i opcje na indeks WIG20 (*Instrumenty pochodne...*).

2017, s. 81–82). Zdaniem przedstawicieli największych korporacji świata (85% spośród 500) instrumenty pochodne są bardzo ważne lub ważne dla ich strategii zarządzania ryzykiem. Średni dzienny obrót instrumentami pochodnymi OTC (będącymi przedmiotem obrotu poza rynkiem regulowanym) wynosi około 2,3 biliona USD, zaś szacunkowa ich wartość rynkowa kształtuje się na poziomie około 25 bilionów USD (*The Value of Derivatives...*).

Instrumenty pochodne z jednej strony odgrywają ważną rolę w zabezpieczaniu i zarządzaniu ryzykiem, z drugiej są jednak także zagrożeniem dla stabilności rynków finansowych oraz gospodarki (przykłady firm bankrutujących z powodu inwestycji w opcje walutowe). Mimo wielu korzyści wynikających chociażby z hedgingu, arbitrażu oraz wykorzystania dźwigni finansowej, w ostatniej dekadzie wolumen i wartość obrotu instrumentami pochodnymi na rynkach światowych i w Polsce uległy ograniczeniu (*Statistical Release...*).

W odniesieniu do kontraktów indeksowych oraz akcyjnych ich umiarkowana popularność w ostatniej dekadzie mogła być następstwem korzystnych tendencji na rynku kapitałowym, widocznych od września 2011 roku. Niemalże wpływ na wymienione tendencje mogły mieć również nowe regulacje dotyczące nieregulowanego rynku instrumentów pochodnych, które wprowadzono w wielu krajach po globalnym kryzysie finansowym (Pyka, Muszyński, 2015, s. 118). Przyczyn spadku dynamiki zainteresowania derywatami szukać zatem należy także w innych obszarach, spośród których kluczowym wydaje się alternatywna możliwość generowania wyraźnie wyższych niż dla rynków akcyjnych oczekiwanych dochodów. Do takich przyczyn należy niewątpliwie powstanie i upowszechnienie rynku walut szyfrowanych (tzw. kryptowalut).

Celem artykułu jest prezentacja koncepcji systemu informatycznego umożliwiającego prognozowanie kursu kryptowaluty bitcoin (BTC) w odniesieniu do waluty euro (EUR). Na potrzeby realizacji tak sformułowanego celu opracowano model sztucznej sieci neuronowej – perceptronu wielowarstwowego (Kłosowski, Klepka, Nowacka, 2018). W ramach badań dokonano doboru zmiennych wejściowych, od których uzależniono kurs BTC. Pozyskano także odpowiednie dane, pochodzące z dziennych notowań kursów wybranych walut i metali. Dane poddano stosownej obróbce matematycznej w celu ich dostosowania do wykorzystania podczas uczenia, walidacji i testowania sztucznej sieci neuronowej (Huang, Lai, Nakamori, Wang, 2004).

Do realizacji celu wykorzystano badania literaturowe, dane finansowe dostępne na portalach finansowych oraz narzędzia statystyczne i ekonometryczne.

1. Geneza i istota rynku kryptowalut


Handel bitcoinem został zainicjowany w 2009 roku, a więc w okresie tuż po kryzysie finansowym. Koncepcja tej kryptowaluty została opracowana w latach 2007–2009 m.in. przez autora dokumentu *Bitcoin: Peer-to-Peer Electronic Cash System*, kryjącego się pod pseudonimem Satoshi Nakamoto.

Bitcoin jest walutą niepaństwową, która korzysta z niepaństwowego systemu płatniczego. System transakcyjny oparty jest na zasobach internetowych i dlatego jest zdecentralizo-

wany, w przeciwieństwie do tradycyjnych systemów płatności. Znaczącą różnicą między konwencjonalnymi walutami a bitcoinem jest to, że kryptowaluty mogą być „emitowane”, a raczej tworzone na całym świecie przez tzw. górników. Osoby te analizują historyczne transakcje bitcoinowe, tworząc tzw. łańcuch bloków *blockchain*, określane także mianem księgi systemu bitcoin, stanowiący swego rodzaju szkielet infrastruktury systemu bitcoin (Möbert, 2018, s. 3). W celu ograniczenia inflacji bitcoinów jego autorzy przewidzieli w algorytmie skończoną ich liczbę, która kiedykolwiek zostanie wygenerowana. Zapobieżono w ten sposób ich nadmiarowi, zapewniając rzadkość tej kryptowaluty (DeVries, 2016, s. 1).

Bitcoin jest zatem wirtualną jednostką pieniężną i dlatego nie ma fizycznej reprezentacji. Jednostka tej kryptowaluty jest podzielna i można ją podzielić na 100 milionów „satoshis”, będących najmniejszą częścią bitcoina. W systemie kryptowalut nie występuje centralny organ z wyłącznym prawem do prowadzenia rachunków. Istnieje za to zdefiniowany zestaw reguł i możliwość indywidualnego monitorowania innych uczestników, którzy zwykle pozostają anonimowi dzięki użyciu pseudonimów (Berentsen, Schär, 2018, s. 4–5). Użytkownicy mogą zatem realizować transakcje bez nadzoru stron trzecich. Pomimo tego, że bitcoin, w odróżnieniu od obiektów fizycznych oraz pierwotnych środków płatności (np. surowców i towarów), nie ma wartości wewnętrznej, jego wartość opiera się głównie na zaufaniu i akceptacji (por. DeVries, 2016, s. 1, 6).

Mimo tego system walut szyfrowanych zyskuje coraz większą popularność. W ciągu dziewięciu lat od rynkowego debiutu bitcoina, liczba kryptowalut notowanych na całym świecie ukształtowała się na poziomie 1501 szt. (Investing.com). Realnym odzwierciedleniem popularności bitcoina jest zmienność jego ceny. W perspektywie ostatnich kilku lat kurs tej kryptowaluty odznaczał się wyjątkowo dużą zmiennością, co umożliwiło inwestorom zrealizowanie wyraźnie wyższej niż w przypadku konwencjonalnych walut, czy też alternatywnych instrumentów finansowych, stopy zwrotu z zaangażowanego kapitału (por. rys. 1).



Rysunek 1. Kurs bitcoina w okresie od września 2016 r. do września 2018 r.


Źródło: *Market Price (USD)*.

Zwiększenie zainteresowania bitcoinem i innymi kryptowalutami wynika bezpośrednio ze wzrostu poziomu zaufania użytkowników, rozwoju technologii IT, upowszechniania Internetu, większych możliwości generowania dochodu, globalnej mobilności itp. (DeVries, 2016, s. 2). Można także postawić hipotezę, że popularność ta jest także efektem spadającego

zaufania do tradycyjnych systemów walutowych oraz polityki monetarnej banków centralnych, szczególnie w kontekście realizacji tzw. luzowania ilościowego (Corbet, McHugh, Meegan, 2017, s. 61). Istotnym motywem może być także fakt nieuregulowania podatkowego w wielu krajach transakcji kryptowalutami, co stwarza możliwość obrotu tymi instrumentami bez konieczności regulowania wysokich zobowiązań wobec organów skarbowych.

Biorąc pod uwagę dynamicznie rosnącą popularność oraz zagrożenia wynikające z handlu kryptowalutami, handel walutami szyfrowanymi porównuje się niekiedy do pierwszej piramidy finansowej, nazywanej schematem Ponziego (*Ponzi Schemes...*). Różnica polega jednak na tym, że o ile schemat i autor pierwszej udokumentowanej piramidy finansowej był w miarę klarowny, o tyle w wypadku rynku kryptowalut autor procesu jest anonimowy, a schemat, a raczej algorytm, ma charakter zdecentralizowany i niezinstytucjonalizowany. Sami zaś uczestnicy tego rynku, w przeciwieństwie do typowej piramidy, nie są biernymi dawcami kapitału, ale realnie kształtują poziom kursu kryptowalut (Kmita, 2017).

Stwierdzić jednak należy, że formułowanie tezy o tzw. spekulacyjnej bańce kryptowalutowej wydaje się nieoparte rzetelną analizą. W zestawieniu największych tego typu wydarzeń w nowożytnej historii rynków kapitałowych wartość rynku walut szyfrowanych, mimo dynamicznego rozwoju tego rynku, w dalszym ciągu pozostaje znikoma (por. rys. 2).



Rysunek 2. Rozmiar największych baniek spekulacyjnych w nowożytnej historii (z uwzględnieniem inflacji)

Źródło: Baumann, Lesoismier (2017), s. 9.

Mimo tego, że obecnie notowanych jest ponad 1,5 tys. różnego rodzaju kryptowalut, rynek ten jest mocno scentralizowany. Dowodem na to jest fakt, że 50% kapitalizacji rynkowej walut szyfrowanych stanowi bitcoin (Baumann, Lesoismier, 2017, s. 13). Na kolejnych miejscach znajdują się następujące kryptowaluty (Baumann, Lesoismier, 2017, s. 14–18):

- ethereum (13% ogólnej kapitalizacji),
- ripple (5%),
- litecoin (poniżej 1%),
- gnosis (ok. 0,4%),
- omisego (ok. 0,3%).

2. Model systemu prognozowania

Z uwagi na to, że pozyskanie danych w postaci dziennych kursów otwarcia walut i metali z poszczególnych dni na przestrzeni ostatnich lat nie nastręcza trudności, zdecydowano się na zastosowanie modelu predykcyjnego opartego na sztucznych sieciach neuronowych typu perceptron wielowarstwowy. Innym argumentem świadczącym na korzyść tego rozwiązania był dostęp do szerokiej wiedzy eksperckiej w zakresie teoretycznej i praktycznej znajomości rynków finansowych i giełd towarowych. Obserwacje i analizy zjawisk zachodzących na powyższych rynkach pozwoliły w szczególności dostrzec korelacje zachodzące między kursami pewnych par walutowych (w tym także bitcoina) oraz cenami miedzi i złota. W sytuacji, kiedy z dużą dozą prawdopodobieństwa można stwierdzić istnienie prawidłowości w zakresie zmian kursów walut i wybranych metali, lecz jednocześnie nie sposób przedstawić skutecznej zależności jednych kursów walut lub cen metali od kursów i cen innych walorów w postaci odpowiedniej formuły matematycznej, odpowiednim rozwiązaniem są heurystyki oraz sztuczne sieci neuronowe.

Na rysunku 3 przedstawiono model neuronowego systemu prognozowania kursu bitcoina. Model zawiera cztery wejścia. Są nimi dzienne kursy otwarcia dwóch par walutowych: EUR/USD, USD/CNH oraz kursy miedzi (USD) i złota (USD). Sieć neuronowa ma jedną warstwę ukrytą, składającą się z 10 neuronów. Wyjściem prezentowanego modelu jest kurs waluty bitcoin (BTC) wyrażony w euro. Zarówno w warstwie ukrytej, jak i w warstwie wyjściowej zastosowano hiperboliczną, stycznie sigmoidalną funkcję przejścia.


Dane wejściowe:

1. EUR/USD
2. USD/CNH
3. Miedź [USD]
4. Złoto [USD]

Wartość

prognozowana:

1. BTC/EUR



Rysunek 3. Model neuronowego systemu prognozowania kursu bitcoina

Źródło: opracowanie własne.

Zauważono, że waluty chińskie, zarówno juan pozakontynentalny CNH, jak i kontynentalny CNY, są silnie skorelowane z bitcoinem. W modelu zastosowano CNH, ponieważ korelacja tej waluty z bitcoinem jest większa ($R \approx +0,72$) niż CNY ($R \approx +0,68$). Ponadto można zauważyć, że wraz z osłabianiem kursu juana od sierpnia 2015 roku ma miejsce wzrost kursu bitcoina. Analogia ta nie jest oczywista, kiedy porównuje się wykresy kursów obu walut w krótkich okresach gwałtownych fluktuacji (np. w sierpniu 2015 r., gdy nastąpiła dramatyczna dewaluacja juana). Sytuacja wydaje się bardziej klarowna, kiedy analizowane są okresy roczne lub dłuższe.

3. Cel badań i metoda badawcza

Celem badań było rozwiązanie problemu związanego z procesem inwestowania na rynku walutowym. Prace badawcze dotyczyły w szczególności opracowania metody prognozowania kursu kryptowaluty BTC na podstawie bieżących danych z rynku walutowego i giełdy towarowej (metali). Ostatecznie powstały dwa modele decyzyjne, z których pierwszy prognozował kurs BTC w horyzoncie czasu wynoszącym jeden dzień, natomiast zadaniem modelu drugiego była analogiczna predykcja w perspektywie dwóch dni.

Jak już wcześniej wspomniano, w badaniach zastosowano metodę symulacji komputerowej z wykorzystaniem sztucznej sieci neuronowej. Opracowano model systemu decyzyjnego, opartego na sztucznej inteligencji. Z uwagi na dostęp do danych historycznych zastosowano perceptron wielowarstwowy z dziesięcioma neuronami w jednej warstwie ukrytej.

Przeprowadzono dwie serie eksperymentów symulacyjnych. Pierwsza miała na celu zweryfikowanie jakości systemu prognozującego kwotowania pary walutowej BTC/EUR z jednodniowym wyprzedzeniem. Seria druga weryfikowała jakość systemu predykcyjnego, przewidującego kurs BTC z wyprzedzeniem dwudniowym.

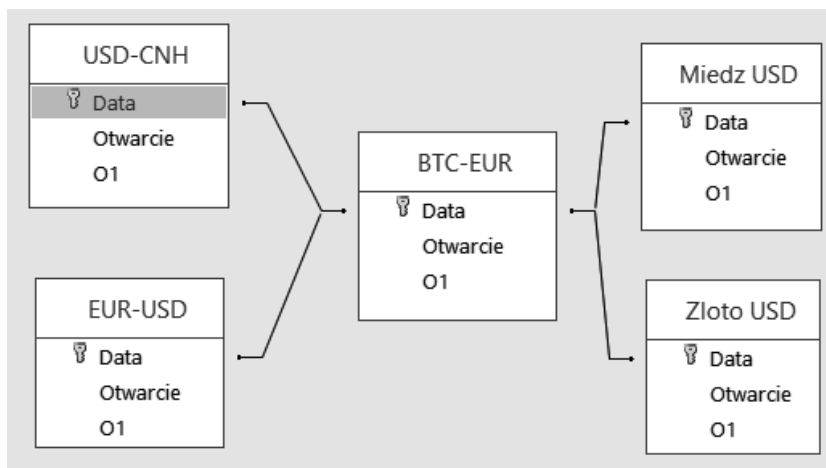
Zbiór danych wykorzystanych w obu modelach zawierał dzienne notowania (kursy otwarcia) czterech wejść i jednego wyjścia. Liczność zbiorów danych wykorzystanych w eksperymencie pierwszym wynosiła 270 przypadków, natomiast w drugim 269 przypadków.

4. Sposób opracowania danych

Dane zostały przygotowane z wykorzystaniem oprogramowania Excel i Access. Utrudnieniem był fakt, że notowania kursów walut fiducjarnych (np. USD, EUR) nie obejmują weekendów i świąt, podczas gdy kryptowaluta bitcoin jest notowana bez przerwy. Prócz tego kalendarz dziennych notowań metali różni się od kalendarza notowań par walutowych. Z tego powodu należało odrzucić dane zawierające niepełne notowania, czyli te, które nie obejmowały wszystkich wartości wejściowych i wyjściowych w danym dniu.

W celu ujednoczenia wielkości wejściowych i wyjściowych wszystkie liczby sprowadzono do wartości z przedziału od 0 do 1. We wszystkich przypadkach zastosowano przeliczenie, w którym wartość rzeczywistą podzielono przez wartość maksymalną spośród wszystkich wartości z całego zbioru danych. Jest to sprawdzona praktyka, zalecana podczas projektowania sztucznych sieci neuronowych. W ten sposób uzyskano metadane, które zaprezentowano w tabeli 2.

Na rysunku 4 przedstawiono relacje typu „jeden do jednego”, łączące wszystkie notowania. Kluczem indeksowania wszystkich macierzy danych jest data. Taki sposób powiązania tabel jest gwarancją spójności danych.



Rysunek 4. Relacje tabel z danymi indeksowanymi według dat notowań

Źródło: opracowanie własne.

W tabeli 1 przedstawiono wstępnie uporządkowane dane. Z uwagi na duże różnice nominalów dane w postaci bezpośredniej mogłyby powodować dodatkowe trudności w wytrenowaniu sieci neuronowej. Należało je poddać dalszej obróbce matematycznej.

Tabela 1

Fragment zbioru danych rzeczywistych

Data notowania	Wejścia				Wyjście
	EUR–USD [USD]	USD–CNH [CNH]	Miedz* [USD]	Zloto** [USD]	BTC/EUR + 1 [EUR]
4.01.2016	1,0856	6,5687	2,071	1063,4	397,2
5.01.2016	1,0829	6,6274	2,074	1075,6	399,86
6.01.2016	1,0746	6,6419	2,079	1081,6	400,38
7.01.2016	1,0778	6,6953	2,06	1091,6	399,49
8.01.2016	1,0931	6,6808	2,018	1111,1	420,03
11.01.2016	1,0922	6,6814	1,976	1105,7	410,67

* Cena za jeden funt.

** Cena za jedną uncję trojańską (jubilerską).

Źródło: opracowanie własne.

W tabeli 2 przedstawiono odpowiednio zredukowane i zagregowane metadane, gotowe do użycia w celu wytrenowania sieci neuronowej prognozującej kurs BTC/EUR z jednodniowym wyprzedzeniem.

Tabela 2

Fragment zbioru metadanych

Data notowania	Wejścia				Wyjście
	EUR–USD	USD–CNH	Miedź	Złoto	BTC/EUR + 1
4.01.2016	0,9415	0,9421	0,7656	0,7752	0,3681
5.01.2016	0,9391	0,9505	0,7667	0,7841	0,3686
6.01.2016	0,9319	0,9526	0,7686	0,7885	0,3678
7.01.2016	0,9347	0,9602	0,7616	0,7958	0,3867
8.01.2016	0,9480	0,9582	0,7460	0,8100	0,3781
11.01.2016	0,9472	0,9582	0,7305	0,8061	0,3814

Źródło: opracowanie własne.

W ramach przeprowadzonych badań przetestowano trzy metody uczenia sieci neuronowej, wykorzystujące algorytmy:

- Levenberga-Marquardta, algorytm wyposażony w funkcję redukcji pamięci przy dużych zbiorach uczących,
- regularyzacji bayesowskiej, zmodyfikowany algorytm Levenberga-Marquardta, opracowany w celu budowania sieci o lepszych własnościach uogólniania, posiadający procedury optymalizacji liczby parametrów sieci (Foresee, Hagan, 1997),
- skalowalny algorytm gradientów sprzężonych, który nie wykorzystuje metody liniowego przeszukiwania w każdej iteracji, ale używa kombinowanej metody algorytmu Levenberga-Marquardta i zbieżności gradientów sprzężonych.

5. Rezultaty eksperymentów z sieciami neuronowymi do prognozowania kursów BTC

Zarówno w przypadku sieci prognozującej kursy CTC w perspektywie jednodniowej, jak i dwudniowej najlepsze efekty uzyskano, stosując algorytm regularyzacji bayesowskiej. Ten typ algorytmu angażuje nieco więcej czasu niż pozostałe algorytmy uczenia sieci, lecz oferuje wysokie wskaźniki generalizacji. Dobre wskaźniki sieci osiągnane są nawet wtedy, gdy zbiór uczący jest zaszumiony i zawiera niewielką liczbę przypadków uczących. Zatrzymanie procesu uczenia następowało w sytuacji, kiedy w kolejnych sześciu iteracjach błąd walidacji nie malał. Ta technika ustalania momentu zakończenia procesu trenowania sieci znana jest pod nazwą wczesnego zatrzymania (*early stopping*). Dzięki jej zastosowaniu, trenowana sieć nie ulega przeuczeniu (*overfitting*) i uzyskuje zdolność generalizacji.

Na rysunku 5 przedstawiono wskaźniki świadczące o jakości uzyskanej sieci. Na uwagę zasługuje zwłaszcza wysoki współczynnik regresji (R) i mały błąd średniokwadratowy (MSE) w obu przypadkach.

Results			
	Samples	MSE	R
Training:	188	3.71119e-4	9.90138e-1
Validation:	41	0.00000e-0	0.00000e-0
Testing:	41	5.66711e-4	9.91067e-1

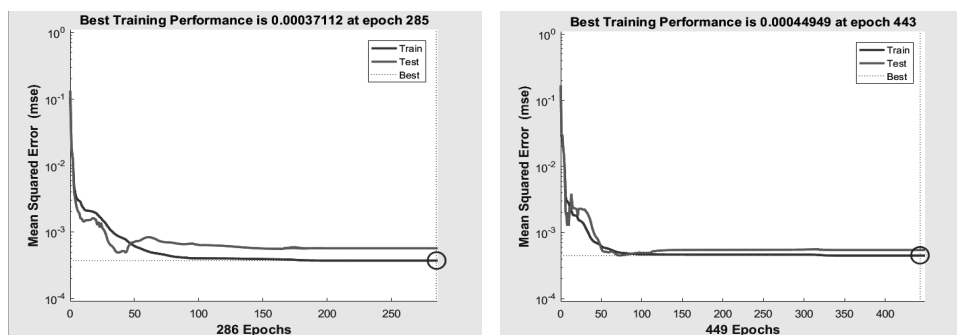
Results			
	Samples	MSE	R
Training:	189	4.49489e-4	9.88426e-1
Validation:	40	0.00000e-0	0.00000e-0
Testing:	40	5.43413e-4	9.88589e-1

Rysunek 5. Rezultaty uczenia sieci do prognozowania BTC w horyzoncie jednodniowym (u góry) i dwudniowym (u dołu)

Źródło: opracowanie własne.

Duże znaczenie mają niski błąd MSE i wysoki (bliski 1) współczynnik R w odniesieniu do zbioru testowego. Przypadki z tego zbioru nie uczestniczą w procesie uczenia sieci, w związku z tym prawidłowe prognozy w odniesieniu do zbioru testowego świadczą o tym, że sieć nie została „przeuczona”. Innymi słowy, niskie wartości MSE i wysokie R świadczą o tym, że opracowany system predykcyjny prawidłowo przewiduje kursy bitcoina nie tylko w odniesieniu do danych historycznych, lecz także dla wartości bieżących i przyszłych.

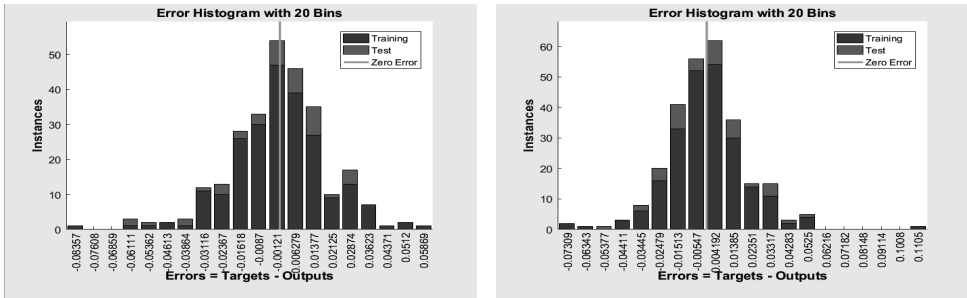
Na rysunku 6 zaprezentowano wykres wartości błędu średniokwadratowego w trakcie procesu uczenia sieci. Zarówno w przypadku predykcji jednodniowej, jak i dwudniowej wartości MSE są niskie. Ponadto kształty wykresów (brak fluktuacji, hiperbola) wskazują na wysoką jakość otrzymanych systemów predykcyjnych.



Rysunek 6. Wykres błędu średniokwadratowego w trakcie uczenia sieci w horyzoncie jednodniowym (po lewej) i dwudniowym (po prawej)

Źródło: opracowanie własne.


Na rysunku 7 zaprezentowano histogramy błędów MSE. Każdy pionowy słupek wskazuje ilość błędów o określonej wartości. Jak widać, największe ilości błędów występują blisko zera. Oba histogramy odpowiadają krzywej Gaussa, odzwierciedlającej rozkład normalny. Fakt ten również potwierdza wysoką jakość otrzymanych sterowników predykcyjnych.




Rysunek 7. Histogram błędów uczenia sieci w horyzoncie jednodniowym (po lewej) i dwudniowym (po prawej)

Źródło: opracowanie własne.

Na rysunku 8 zaprezentowano wykresy rozrzutu odzwierciedlające korelację odpowiedzi udzielanych przez sieć neuronową z odpowiedziami prawidłowymi. Dwa górne rysunki odpowiadają sterownikowi prognozującemu kurs BTC z wyprzedzeniem jednodniowym. Dwa dolne dotyczą prognozowania dwudniowego. Wykresy po lewej stronie obrazują rozkład przypadków dla zbioru uczącego, natomiast lewa strona wykresów odpowiada zbiorowi testowemu. Można zauważyć, że skupienie odpowiedzi jest bliskie linii odpowiadającej odpowiedziom prawidłowym. Ma to szczególne znaczenie w przypadku zbioru testowego, o czym już wcześniej wspomniano.





Rysunek 8. Diagramy korelacyjne uczenia sieci do prognozowania BTC w horyzoncie jednodniowym (u góry) i dwudniowym (u dołu)

Źródło: opracowanie własne.

Uwagi końcowe

Przeprowadzona analiza dowodzi, że zastosowanie sztucznych sieci neuronowych do prognozowania kursu bitcoina znajduje swoje uzasadnienie w otrzymanych wynikach. Wysokie wartości współczynnika regresji (R) i mały błąd średniokwadratowy (MSE) świadczą o tym, że opracowany system predykcyjny prawidłowo przewiduje kursy analizowanej kryptowaluty nie tylko w odniesieniu do danych historycznych, lecz także dla wartości bieżących i przyszłych. Świadczy to o wysokiej zdolności uzyskanej sieci do generalizacji.

Otrzymane wyniki upoważniają do stwierdzenia, że mimo wysokiej zmienności kursów kryptowalut można znaleźć zmienne niezależne (predyktory), których poziomy cenowe są wyraźnie dodatnio skorelowane z poziomem cen walut szyfrowanych. Podkreślić należy, że rezultaty przeprowadzonej analizy są miarodajne w odniesieniu do kursu bitcoina, na podstawie analiz konkretnego szeregu czasowego. Uwzględnienie innego horyzontu czasowego lub też zastosowanie w modelu innej kryptowaluty prawdopodobnie skłoniłyby do odmiennej konkluzji. Niemniej poszukiwanie determinant zmian poziomów cenowych kryptowalut stanowi swego rodzaju koncepcję próby algorytmizacji z pozoru nieprzewidywalnych zachowań graczy giełdowych. Odszukanie w przyszłości sieci powiązań kursu walut szyfrowanych z takimi zmiennymi jak ceny surowców, kursy walut tradycyjnych czy koniunktura na rynku akcji, umożliwiłoby pośrednie wkomponowanie elementów analizy fundamentalnej do rynku, który został stworzony po to, by dla tradycyjnych wzorców giełdowych stanowić alternatywę. Dowiodłoby to jednak tezy o globalnym systemie finansowym jako układzie naczyń połączonych, nawet w odniesieniu do rynku, który miał ten system zrewolucjonizować.

Literatura

- Baumann, J., Lesoismier, A. (2017). *Cryptocurrencies Outlook 2018. Stairway to Heaven*. SwissBorg.
- Berentsen, A., Schär, F. (2018). A Short Introduction to the World of Cryptocurrencies. *Federal Reserve Bank of St. Louis Review*, First Quarter.
- Bitcoin Correlations to Macro Environment: Gold and Yuan Standouts*. TradeBlock. Pobrano z: <https://tradeblock.com/blog/bitcoin-correlations-to-macro-environment-gold-and-yuan-standouts> (31.11.2017).
- Corbet, S., McHugh, G., Meegan, A. (2017). The Influence of Central Bank Monetary Policy Announcements on Cryptocurrency Return Volatility. *Investment Management and Financial Innovations*, 4 (14), 60–72.
- DeVries, P.D. (2016). An Analysis of Cryptocurrency, Bitcoin, and the Future. *International Journal of Business Management and Commerce*, 1 (2), 1–9.
- Foresee, F.D. Hagan, M.T. (1997). Gauss-Newton Approximation to Bayesian Learning. W: *Proceedings of the International Joint Conference on Neural Networks* (s. 1930–1935). Houston: IEEE.
- Huang, W., Lai, K.K., Nakamori, Y., Wang, S. (2004). *Forecasting Foreign Exchange Rates with Artificial Neural Networks: A Review*. *International Journal of Information Technology & Decision Making*, 3 (01), 145–165.
- Instrumenty pochodne*. GPW. Pobrano z: <https://www.gpw.pl/instrumenty-pochodne> (10.09.2018).
- Investing.com. Zakładka: Kryptowaluty. Pobrano z: <https://m.pl.investing.com/> (10.09.2018).
- Kłosowski, G., Klepka, T., Nowacka, A. (2018). Neural Controller for the Selection of Recycled Components in Polymer-gypsy Mortars. *Applied Computer Science*, 2 (14), 48–59.
- Kmita, M. (2017). *Dlaczego Bitcoin nie jest piramidą finansową*. BitHub.pl. Pobrano z: <https://bithub.pl/opinie/dlaczego-bitcoin-piramida-finansowa/> (13.09.2018).
- Market Price (USD)*. Blockchain. Pobrano z: <https://www.blockchain.com/charts/market-price?timespan=2years> (13.09.2018).
- Möbert, J. (2018). *Bitcoin Myths, Misconceptions and Misunderstandings*. EU Monitor Global Financial Markets. Deutsche Bank Research.
- Ponzi Schemes Using Virtual Currencies*. SEC Investor Alert. Pobrano z: https://www.sec.gov/investor/alerts/ia_virtualcurrencies.pdf (13.09.2018).
- Pyka, I., Muszyński, M. (2015). Nowe regulacje bezpiecznego obrotu instrumentami pochodnymi na rynku pozagiełdowym w Polsce. *Studia Ekonomiczne. Zeszyty Naukowe Uniwersytetu Ekonomicznego w Katowicach*, 238, 117–131.
- Stankovska, A. (2017). Global Derivatives Market. *SEEU Review*. Pobrano z: <https://www.degruyter.com/downloadpdf/j/seeur.2016.12.issue-1/seeur-2017-0006/seeur-2017-0006.pdf> (10.09.2018 r).
- Statistical Release: OTC Derivatives Statistics at End – June 2017* (2017). Bank of International Settlements. Pobrano z: https://www.bis.org/publ/otc_hy1711.pdf (11.09.2018).
- The Value of Derivatives*. Pobrano z: <https://www.isda.org/a/qJEDE/isda-final-2014.pdf> (12.09.2018).

FORECASTING THE BITCOIN RATE USING AN ARTIFICIAL NEURAL NETWORK

Abstract: *Purpose* – The aim of the article is to present the concept of an IT system that allows forecasting of the bitcoin cryptocurrency rate in relation to the euro.

Design/methodology/approach – For the needs of pursuing such a formulated goal, an artificial neural network model – a multi-layer perceptron was developed. As part of the research, the input variables on which the BTC exchange rate was based were selected. Relevant data from daily quotations of exchange rates of selected currencies and metals were also obtained. The data was subjected to appropriate mathematical processing in order to adapt them for use during teaching, validation and testing of the artificial neural network.

Originality/value – The results of the conducted experiments confirmed the high effectiveness of forecasting in one and two days perspective. High values of the regression coefficient (R) and small mean square error (MSE) indicate that the developed prediction system correctly predicts the rates of the analyzed cryptocurrency not only in relation to historical data, but also for current and future values.

Keywords: stock market, cryptocurrencies, forecasting of exchange rates, artificial neural network

Cytowanie

Paździor, A., Kłosowski, G. (2018). Prognozowanie kursu bitcoina z wykorzystaniem sztucznej sieci neuronowej. *Finanse, Rynki Finansowe, Ubezpieczenia*, 4 (94/2), 61–73. DOI: 10.18276/frfu.2018.94/2-05.