

Michał CZEMARMAZOWICZ, Ireneusz J. JÓŹWIAK, Robert KORCZAK
Politechnika Wroclawska
Wydział Informatyki i Zarządzania
Instytut Informatyki

WSPOMAGANIE PODEJMOWANIA DECYZJI ORAZ ODNAJDYWANIE WZORCÓW MAKSYMALIZUJĄCYCH ZYSK NA GIEŁDZIE

Streszczenie. W artykule opisano problem prognozowania cen akcji na giełdzie papierów wartościowych i przedstawiono sposób rozwiązania tego problemu za pomocą sieci neuronowej i algorytmu ewolucyjnego. Dokonano implementacji algorytmu i przedstawiono jego ocenę.

SUPPORT DECISION-MAKING AND FINDING STANDARDS MAXIMIZE PROFIT ON THE EXCHANGE

Summary. In the paper the issue of predicting the shares' prices on the stock-exchange was considered. The problem of forecasting the shares' prices on the stock-exchange was described and the solution of this problem by means of neural network and evolutionary algorithm was presented. The implementation of the algorithm was made and the evaluation was submitted.

1. Wprowadzenie

Dwie wielkie tajemnice zdominowały nasz świat – miłość oraz pieniądz. Prawdopodobnie nikt nie będzie miał wątpliwości, co do słuszności stwierdzenia, iż pierwsza z nich jest nieporównywalnie większa, a wagi jej istoty nie pojmiemy pewnie do końca naszych dni. W odniesieniu do drugiej, choć tak diametralnie różnej, możemy stwierdzić, że spotykają się w jednym punkcie – obie są nam w życiu potrzebne. Powstaje w takim razie pytanie, jak je zdobyć? Opisanie pierwszej nie jest przedmiotem rozważań w niniejszym artykule. Jeśli zaś

chodzi o drugą, poniższa praca spróbuje wskazać jedną z możliwości generowania przychodu oraz narzędzia, jakim można się posłużyć przy jego zdobywaniu. Mowa tu o wykorzystaniu sztucznej inteligencji na rynku papierów wartościowych.

2. Giełda – ogólne informacje, nawiązanie do potrzeby szukania nowych narzędzi

Giełda papierów wartościowych (dalej nazywana giełdą) to miejsce, w którym odbywają się transakcje papierów wartościowych, do których należą: obligacje, prawa poboru, prawa do akcji, certyfikaty inwestycyjne, instrumenty pochodne oraz akcje, na których w tym artykule się skupimy. Proces ten działa na zasadzie kojarzenia ze sobą w jednym czasie ofert kupujących z ofertami sprzedających danego instrumentu, co, oprócz realizacji transakcji, wyznacza jego kurs giełdowy. Patrząc na giełdę pod kontem zysków, nie możemy zapomnieć, iż jednym z najważniejszych aspektów nabywania akcji danej spółki jest fakt, że stajemy się współwłaścicielem jej majątku.

Jeśli chodzi o zysk sprawa jest teoretycznie trywialna. Osiągamy go przez sprzedaż akcji po cenie wyższej niż cena zakupu bądź też przez wypłatę dywidend. Przeszkodą w pierwszym przypadku jest trudność przewidzenia przyszłych trendów oraz zmian wartości akcji. Z pomocą przychodzi nam analiza fundamentalna oraz analiza techniczna. Pierwsza z nich polega na szacowaniu wartości akcji danej spółki na podstawie jej okresowych raportów, analiz rynkowych i prospektów emisyjnych przy jednoczesnym uwzględnieniu wpływu makrootoczenia. Analiza techniczna w przeciwieństwie do fundamentalnej zakłada, iż wartość przyszłej ceny można odczytać z wykresu jej historycznej zmienności – wystarczy więc obserwować notowania i prowadzić badania. Mamy w tym momencie wszystko, co jest nam potrzebne, aby prognozować wzrosty bądź spadki. Jedną z najskuteczniejszych metod analizy technicznej są świece japońskie [4]. Przekazują one znacznie więcej informacji niż wykresy liniowe cen akcji. Do ich sporządzenia używa się cen: otwarcia, najwyższej i najniższej dnia oraz zamknięcia.

Mimo całego spektrum analitycznych narzędzi, niezliczonej liczby książek i poradników do gry na giełdzie, nie istnieje pewny sposób na zysk [3]. Co więcej, większość inwestorów indywidualnych traci. Jednak nie możemy zaprzeczyć temu, iż pewnym osobom ich strategie przynoszą regularny zysk. W pracy rozpatrzono problem przewidywania notowań i zasugerowano rozwiązanie wspomagające podejmowanie decyzji podczas gry na giełdzie.

3. Sztuczna inteligencja jako narzędzie pomocne w analizie technicznej

Jeśli wiemy, że wszystko, co mogło wpłynąć na cenę ma rzeczywisty udział w jej kreacji, a zachowania ceny mają często charakter cykliczny, powstają pytania, jak trudno jest przewidzieć zmiany cen akcji oraz jakie narzędzia mogą nam w tym pomóc? Odpowiedź nasuwa się równie szybko, co pytanie – czynniki, które jesteśmy w stanie wziąć pod uwagę, są ograniczone, a ludzie nie dysponują odpowiednią mocą obliczeniową. Z pomocą przychodzi nam komputer wraz z algorytmami sztucznej inteligencji [2]. Kwintesencją rozwiązania byłaby odpowiednio wyuczona sieć neuronowa, której struktura zastałaby dobrana przez wykorzystanie algorytmu ewolucyjnego [1].

3.1. Przedstawienie sieci neuronowej jednokierunkowej, uczonej metodą nadzorowaną

Sieć neuronowa jest to struktura matematyczna, która dobiera swoje parametry, tak aby jak najwierniej odwzorować schematy przedstawione przez dane uczące. Sieć taką uczy się parami danych X i Y , gdzie X jest wektorem wejściowym $X = \{x_1, x_2, \dots, x_n\}$, a Y jest wektorem wyjściowym $Y = \{y_1, y_2, \dots, y_m\}$, a zbiór par jest zbiorem uczącym $S = \{(X_1:Y_1), (X_2:Y_2), \dots, (X_k:Y_k)\}$. Zbiór ten powinien być tak utworzony, że nie istnieją dwie lub więcej pary, które mają taki sam wektor wejściowy, a różny wektor wyjściowy. Jeżeli zdarzy się taka sytuacja, to sieć nie będzie w stanie się nauczyć.

Sieć neuronowa zbudowana jest z warstw neuronów. Pierwszą warstwą jest warstwa wejściowa, na którą są podawane odpowiednio wartości x_1, x_2, \dots, x_n , z wektora wejściowego do odpowiadających neuronów. Następnie są warstwy ukryte neuronów, dzięki którym sieć jest w stanie nauczyć się rozróżniać wektory wejściowe i przyporządkowywać im wektory wyjściowe. Ostatnią warstwą jest warstwa wyjściowa, która wyprowadza wartości z sieci, odpowiednio y_1, y_2, \dots, y_m . Każdy neuron z warstw ukrytej i wyjściowej jest połączony ze wszystkimi neuronami z warstwy poprzedzającej. Jest to potrzebne, ponieważ do tych połączeń są przypisywane wagi kluczowe dla działania całej sieci. W wykorzystaniu sieci neuronowej ważne jest, żeby wartości wejściowe i wyjściowe były znormalizowane z przedziału $(-1, 1)$, ponieważ dużo większe wartości niż inne w wektorze wejściowym zakłócałyby wynik.

Przy odpowiednim dobieraniu struktury sieci zyskuje ona umiejętność uogólniania. Gdy poda się jej wektor wejściowy, który nie był uczącym, jest ona w stanie wygenerować wektor wyjściowy na podstawie zapamiętanych schematów. Istnieje jednak niebezpieczeństwo, że przeuczmy sieć i straci ona tę umiejętność.

3.2. Założenia algorytmu genetycznego

Algorytm genetyczny jest metodą przeszukiwania przestrzeni rozwiązań problemu i wyboru z niej najlepszych rozwiązań. Idea przeszukiwania, inspirowana ewolucją, jest taka, aby wybrać z populacji dwóch rodziców dobrze dostosowanych do środowiska i skrzyżować ich tak, by ich potomstwo było przystosowane lepiej niż rodzice. Środowiskiem jest jakiś problem, a każde rozwiązanie tego problemu osobnikiem. Każdy osobnik, by rozwiązać problem, potrzebuje swojego zestawu parametrów. Każdy parametr to inaczej gen, który zapisujemy w chromosomie. Osobnik podlega ocenie przez funkcje oceny, która określa, jak dobrze jest on dostosowany do środowiska problemu, który staramy się rozwiązać.

Populacja jest pewnym podzbiorem z przestrzeni rozwiązań, a pierwsza generacja populacji jest tworzona losowo, najlepiej tak, żeby rozwiązania były rozsiane po całej przestrzeni. Następnie oceniamy wszystkie osobniki z generacji i z większym prawdopodobieństwem wybieramy te, które są lepiej dostosowane. Wybraną parę krzyżujemy, a potomków dodajemy do nowej generacji. W trakcie krzyżowania mogą zachodzić mutacje, których zadaniem jest zwiększyć różnorodność genów. Bez mutacji szybko dochodzi do zdegenerowania cech osobników. Wybieramy pary tyle razy, ile to konieczne, aby zachować stałą liczbę osobników w generacji i ustaloną liczbę razy powtarzamy proces tworzenia następnych generacji.

Takie przeszukiwanie przestrzeni rozwiązań jest niewrażliwe na różnego rodzaju utrudnienia, jak nieciągłości czy głębokie minima lokalne.

4. Wykorzystanie sieci neuronowej i algorytmu genetycznego do przewidywania zmiany ceny akcji na giełdzie

Celem, do którego dążymy, jest aplikacja, która przewidywałaby zmiany ceny akcji. Po wprowadzeniu danych, np. dzisiejszych, program przedstawi, jakie zmiany cen akcji na giełdzie papierów wartościowych w procentach przewiduje od dzisiaj za tydzień, dwa, trzy i cztery tygodnie. Zmiany te mogłyby być dodatnie (wzrost ceny akcji) lub ujemne (spadek ceny), co pomogłoby podjąć decyzję inwestorowi, czy sprzedawać czy kupować akcje.

4.1. Opis sieci neuronowej dla problemu przewidywania wartości indeksu giełdowego

Rdzeniem aplikacji jest sieć neuronowa, której wyjścia wyprowadzają 4 wartości $\{y_1, y_2, y_3, y_4\}$, gdzie y_i oznacza procentowy przyrost ceny, a indeks i wskazuje liczbę tygodni. Wektorami wejściowymi zaś są dane z wcześniejszych dni. Wektory te są tak zdefiniowane, że na każdy dzień przypadająby 4 wartości – ceny: otwarcia, zamknięcia, najmniejsza i największa z dnia. Na ich podstawie chcemy sprawdzić, czy sieć jest w stanie się nauczyć przewidywać

zmiany ceny akcji, wykorzystując metodę świec japońskich jako jedną ze skuteczniejszych metod. Nie można jednak zbudować wektora wejściowego, który miałby wartości w złotych i w innej walucie. Należy wszystkie wartości znormalizować. Wzór ogólny wektora wejściowego ma postać $X = \{x_{11}, x_{12}, x_{13}, x_{14}, \dots, x_{n1}, x_{n2}, x_{n3}, x_{n4}\}$, gdzie n oznacza liczbę dni, a kolejno 1, 2, 3, 4 ceny: otwarcia, zamknięcia, najmniejszej i największej z dnia. Każda wartość x_{ij} , $0 < i \leq n$, $0 < j \leq 4$ wyraża się wzorem:

$$x_{ij} = \frac{c_{ij} - c_0}{c_0}, \quad (1)$$

gdzie: c_{ji} jest ceną z i -tego wcześniejszego dnia, $j=1$ jest ceną otwarcia, $j=2$ jest ceną zamknięcia, $j=3$ jest najmniejszą ceną z dnia, $j=4$ jest największą ceną z dnia, a c_0 jest ceną otwarcia z bieżącego dnia.

Podobnie należy znormalizować wartości wyjściowe $Y = \{y_1, y_2, y_3, y_4\}$, z tą różnicą, że mamy tam tylko ceny zamknięcia:

$$y_i = \frac{c_i - c_0}{c_0}, \quad (2)$$

gdzie c_i jest ceną zamknięcia po „ i ” tygodniach.

Nie jesteśmy zależni od waluty czy też od tego, że cena jest rzędu tysięcy czy kilku złotych. Co więcej, pozwala to sieci lepiej generalizować i znajdować schematy, właśnie dzięki normalizacji. Powstają jednak pytania: Jaką liczbę dni mamy podać sieci, żeby ich liczba była odpowiednia? Ile warstw ukrytych i ile neuronów w warstwach da najlepsze rezultaty? Jeśli przeszukamy całą przestrzeń rozwiązań, starając się nawet zachować granice (np. że wektor wejściowy tylko z dni na miesiąc wcześniej i do 4 warstw ukrytych), to i tak sensownych możliwości do sprawdzenia jest około $1.3 \cdot 10^7$. Dlatego do znalezienia efektywnej struktury sieci wykorzystano algorytm ewolucyjny.

4.2. Algorytm ewolucyjny jako narzędzie do znalezienia optymalnej struktury sieci

Jak wcześniej opisano, przestrzeń możliwych struktur sieci jest bardzo liczna, a sprawdzenie wszystkich – prawie niemożliwe, dlatego wykorzystano tu algorytm genetyczny.

Strukturę sieci neuronowej można opisać parametrami: liczbą warstw ukrytych i liczbą neuronów w warstwach, pomijając warstwę wyjściową, która ma stałą liczbę neuronów. Oznacza to, że w zależności od tego, ile będzie warstw ukrytych, tyle więcej parametrów będzie potrzebnych. Budując chromosom, zapisujemy informacje, gdzie pierwszy gen określa liczbę warstw ukrytych, a następne geny liczbę neuronów w warstwach. Oznacza to, że osobnicy mogą mieć różną długość chromosomów, co trzeba mieć to uwadze przy ich krzyżowaniu.

Każdy osobnik podlega ocenie przez funkcje oceny. Mając osobnika, wiemy, jaką strukturę sieci opisuje. Należy ją zbudować i wyuczyć. Zbiór uczący S , który jest parą (X, Y) , powstaje ze zgromadzonych danych z przeszłości z różnych spółek. Dane takie są dostępne w Internecie. Osobnik wskazuje liczbę wejść sieci czy też liczbę badanych dni wstecz. Wielkości te należy podać sieci jako wektor wejściowy. Dla przykładu, mamy dane dwóch spółek z okresu trzech miesięcy, a w chromosomie osobnika jest zapisana informacja, że należy podać sieci na wejście 14 dni wstecz. Mając około 91 dni dwóch spółek, tworzymy pierwszą parę dla pierwszej spółki. X to 56 wartości x_{ij} , wyliczanych ze wzoru (1), gdzie c_{ij} jest ceną akcji z pierwszych 14 dni. Po obliczeniu wartości ze wzoru (1) dodajemy ją do wektora wejściowego. Natomiast Y to cztery wartości y_i , gdzie c_i , to ceny zamknięcia z 22, 29, 36 i 43 dnia, tak samo po wyliczeniu wartości ze wzoru (2) zapisujemy jako wektor Y . Z tak utworzonych X i Y tworzymy parę i dodajemy do zbioru. Sporządzamy następny wektor wejściowy dla dnia 16, czyli 1 dzień opuszczamy. Następne 14 dni (czyli 2-15) tworzy wektor 56 wartości, a z cen z 23, 30, 37 i 44 dnia opracowujemy wartości y_i dla następnego wektora wyjściowego. Zestawione pary dodajemy. Następne dni i druga spółka dają nam 98 par uczących w zbiorze S . Zbiór ten rośnie liniowo z większą liczbą dni i spółek, które chcemy wyuczyć.

Część z tak utworzonego zbioru służy do wyuczenia sieci, a dopełnienie zbioru – do testów poprawności przewidywań. Definiując jakąś miarę odległości między dwoma wektorami, np. euklidesową, możemy zmierzyć odległość między wektorem wyprowadzonym z sieci Y' dla wektora X a wektorem Y będącego parą dla X . Wartość funkcji oceny dla osobnika jest średnią odległością między Y' a Y z każdej pary ze zbioru testowego.

Należy zwrócić uwagę na to, co jest ważne przy projektowaniu metod krzyżowania, a także jaką ideą można się kierować w tym konkretnym problemie. Przedstawiony problem jest podobny do znajdowania minimum funkcji, ponieważ chcemy minimalizować odległość wektorów Y' i Y . Mając dwóch rodziców do skrzyżowania, można porównać, który z nich jest lepiej przystosowany i stworzyć dzieci, które są bardziej podobne do tego rodzica. Mutacją może być losowe dodawanie lub odjęcie pewnej liczby neuronów w warstwie czy zmiana liczby tych warstw. Takie mutacje będą skuteczne i dla początkowych generacji, i dla końcowych, ponieważ zmiana jednej czy dwóch wartości o jedną lub dwie jednostki nie wpłynie znacząco na wartość funkcji oceny.

5. Podsumowanie oraz kierunki badań

Aplikacja, opracowana za pomocą algorytmu przedstawionego w artykule, pozwoli odpowiedzieć na pytanie, w jakim stopniu sieć neuronowa jest w stanie przewidywać giełdę?

Ponieważ wychodzimy z założenia, że w cenie akcji są zawarte wszystkie dane, więc będziemy także mogli sprawdzić, czy jest to prawdziwe założenie. Algorytm ewolucyjny znajdzie nam najlepszą strukturę rozwiązania problemu. Będzie ona mogła przewidywać, ze skutecznością bliską 100%, iż w cenie akcji są zawarte wszystkie dane, że jest to założenie prawdziwe. Są jeszcze inne czynniki, które wpływają na zdolność przewidywania, o których nie wspomniano w niniejszym artykule. Często na cenę akcji mają wpływ poważne zdarzenia, np. powódzie, i inne zdarzenia losowe, jak np. zdrowie prezesa firmy. Nowym kierunkiem byłoby ocenianie i zbieranie takich wydarzeń i zapisywanie ich w wektorze wejściowym. To spowoduje znaczące problemy z tworzeniem takiego wektora wejściowego. Zatem, kierunkiem badań jest sprawdzenie, czy z takimi informacjami można lepiej przewidywać giełdę.

W opisanej sieci neuronowej wszystkie neurony z warstwy następującej są połączone z neuronami warstwy poprzedzającej. Zostały przeprowadzone badania, z których wynika, że nie zawsze jest to pożądana cecha sieci i algorytm ewolucyjny mógłby znaleźć strukturę ze zmodyfikowanymi połączeniami.

BIBLIOGRAFIA

1. Kwaśnicka H.: Ewolucyjne projektowanie sieci neuronowych. Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2000.
2. Markowska-Kaczmar U., Kwaśnicka H.: Sieci neuronowe w zastosowaniach. Oficyna Wydawnicza Politechniki Wrocławskiej, Wrocław 2005.
3. Murphy J.J.: Analiza techniczna rynków finansowych. WIG Press, Warszawa 1999.
4. Nison S.: Świece i inne japońskie techniki analizowania wykresów. WIG Press, Biblioteka Inwestora, Warszawa 1996.

Recenzent: Dr hab. inż. Jan Kałuski, prof. nzw. w Politechnice Śląskiej

Abstract

This article tries to present convention on prediction stock prices on the stock-exchange. Idea concluded in the article is to create application based on knowledge of technical analysis that uses the tools of artificial intelligence.

After short presentation of neural network and evolutionary algorithms comes main idea: to combine tools of artificial intelligence. Core of the application would be neural network created by using evolutionary algorithms. Using them we will determine the number of hidden layers and number of neurons in layers, that will predict the most exact results.

That article gives opportunity to help to answer the question of how precise would the neural network be able to predict stock market.

BIBLIOGRAFIJA

1. Kozłowski J.: *Evolutionary programming and neural networks*. *Prace Instytutu Inżynierii i Techniki Wzrostu* 2002.

2. Kozłowski J., Kozłowski H.: *Stwierdzenie liczby warstw i neuronów w sieciach neuronowych*. *Prace Instytutu Inżynierii i Techniki Wzrostu* 2002.

3. Kozłowski J., Kozłowski H.: *Wykorzystanie algorytmów ewolucyjnych do optymalizacji struktury sieci neuronowych*. *Prace Instytutu Inżynierii i Techniki Wzrostu* 2002.

4. Kozłowski J., Kozłowski H.: *Wykorzystanie algorytmów ewolucyjnych do optymalizacji struktury sieci neuronowych*. *Prace Instytutu Inżynierii i Techniki Wzrostu* 2002.

5. Kozłowski J., Kozłowski H.: *Wykorzystanie algorytmów ewolucyjnych do optymalizacji struktury sieci neuronowych*. *Prace Instytutu Inżynierii i Techniki Wzrostu* 2002.

Abstract

The article tries to present convenient method of combining neural networks and evolutionary algorithms. The main idea is to create application based on knowledge of technical analysis. The article gives opportunity to help to answer the question of how precise would the neural network be able to predict stock market.