

Zastosowanie strategii ewolucyjnej w prognozowaniu tendencji zmian kursu akcji

Krzysztof MURAWSKI¹, Monika MURAWSKA²

¹ Instytut Teleinformatyki i Automatyki WAT, ² Instytut Organizacji i Zarządzania WAT
ul. Gen. S. Kaliskiego 2, 00-908 Warszawa
k.murawski@ita.wat.edu.pl, monika.murawska@wat.edu.pl

STRESZCZENIE: W artykule wyznaczono tendencję zmian kursu akcji, wykorzystując strategię ewolucyjną oraz notowania historyczne. Na bazie doświadczeń pokazano, że strategia ewolucyjna umożliwia poprawne dopasowanie, kodowanego w genotypie, ciągu poszukiwanych wartości kursu akcji do wartości notowanych na giełdzie papierów wartościowych. Następnie genotyp zmodyfikowano, by umożliwić wyznaczanie przyszłych tendencji zmian kursu (prognozy). Sposób prognozowania zweryfikowano dla trzynastu wybranych przedsiębiorstw, których dane uzyskano z Giełdy Papierów Wartościowych w Warszawie.

SŁOWA KLUCZOWE: obliczenia ewolucyjne, strategia ewolucyjna, prognozowanie.

1. Wprowadzenie

Artykuł jest nawiązaniem do dyskusji, która rozpoczęła się w 1959 roku. Wówczas Arthur Samuel sformułował pytanie: *How can computers be made to do what needs to be done, without being told exactly how to do it?*. Choć pytanie jest wciąż aktualne, to jednak wydaje się, że rozwijane obecnie metody sztucznej inteligencji coraz bardziej zbliżają nas do udzielenia na nie odpowiedzi.

Przedmiotem prac było opracowanie sposobu prognozowania tendencji zmian kursu akcji (*ZKA*) obserwowanych na kolejnych sesjach giełdy papierów wartościowych (*SGPW*). Zadanie postanowiono rozwiązać, stosując strategię ewolucyjną (*ES*). Zastosowanie algorytmów sztucznej inteligencji w badaniu zachowań rynku jest znane w ekonomii [4]. Publikowane prace są głównie rozszerzeniem podejścia klasycznego, w którym przyszłość przewiduje się, wyznaczając parametry modelu ekonometrycznego linii trendu [14] lub posługując się metodami statystycznymi. Model buduje się na podstawie danych

archiwalnych [12], [16]. Zwykle, tak jak w [4], [10], [15], zakłada się, że zmiany kursu akcji w przyszłości będą odbywać się zgodnie z regułami obowiązującymi w przeszłości. Odkrywanie reguł działających na kurs akcji przedsiębiorstwa najczęściej odbywa się przez poszukiwanie analogii w linii trendu między wydzielanymi arbitralnie okresami. Odkryte podobieństwa wraz z teorią ekonomii i wiedzą pochodzącą z praktyki służą do budowy modelu ekonometrycznego. Wartości zmiennych modelu poszukuje się, stosując, na przykład, sieci neuronowe [23] oraz algorytmy ewolucyjne [1], [12]. Użycie modelu formalnego zbudowanego na podstawie danych archiwalnych do przewidywania przyszłości jest jednocześnie obiecujące i trudne. Trudność przewidywania *ZKA* wynika z niepewności, czy w zgromadzonych danych zaobserwuje się jakieś reguły działające na kurs akcji oraz czy będą one oddziaływały w przyszłości.

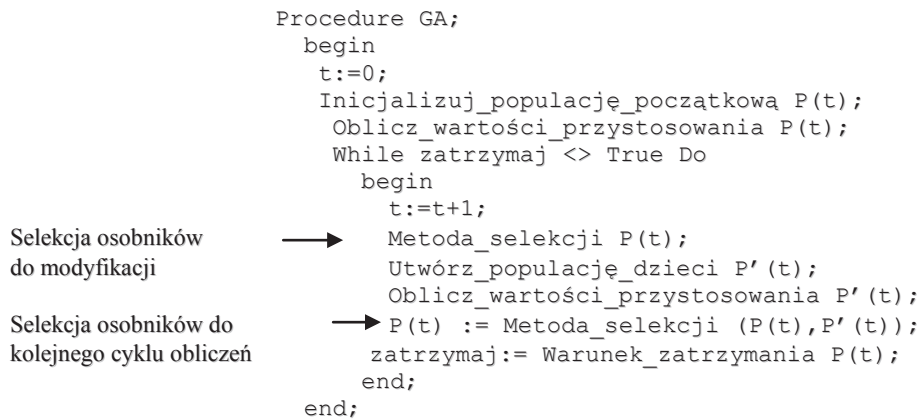
W artykule zaproponowano odmienne podejście do przewidywania tendencji zmian kursu akcji. Tak jak w [12] za podstawę prognozowania przyjęto n historycznych notowań kursu akcji. Następnie utworzono ciąg n zainicjowanych losowo obserwacji, które zakodowano w strukturze nazywanej genotypem. Pierwszych $n-t$ elementów genotypu odpowiadało znanym wartościom kursu akcji, pozostałe tworzyły prognozę. Zakres prognozy był parametrem algorytmu. Kluczowe dla generowanej prognozy były reguły wyznaczania wartości elementów genotypu. W tym celu użyto strategię ewolucyjną. Wartości elementów genotypu określa się w niej na drodze poszukiwania losowego z pamięcią. Dzięki temu charakter zmian wartości był ewolucyjny, a nie gwałtowny. Jednocześnie proces poszukiwania kontrolowano przy wykorzystaniu funkcji przystosowania. W kolejnych iteracjach algorytmu ewolucyjnego wskazywała ona te rozwiązania (osobniki, instancje genotypu), których wyznaczone wartości obserwacji były bliższe znanym wartościom kursu akcji. Rozwiązania oceniane przez funkcję przystosowania były wynikiem działania operatorów genetycznych: krzyżowania i/lub mutacji. Operatory te oddziaływały na wszystkie zmienne genotypu (obserwacje i prognozę). Reguły przetwarzania osobników wynikały z wartości zmiennych, które modyfikowano dynamicznie: prawdopodobieństwa krzyżowania i mutacji. Ich zmienność nie jest możliwa do przewidzenia zarówno przy starcie algorytmu, jak i w trakcie jego działania. Dzięki temu instancje genotypu podlegały ciągłej ewolucji kontrolowanej jedynie przez funkcję przystosowania.

Wynikiem działania obliczeń ewolucyjnych jest n wartości genotypu dopasowanych do historycznych wartości kursu akcji oraz t wartości tworzących prognozę.

2. Obliczenia ewolucyjne

Pierwsze publikacje na temat obliczeń ewolucyjnych (*EA*) pochodzą z lat 1950 – 1960 [1] – [6]. Ich efektem są metody: programowanie ewolucyjne (*EP*) [7]; strategia ewolucyjna (*ES*) [8]; algorytm genetyczny (*GA*) [9]. Można przyjąć, że do dnia dzisiejszego idea działania *EA* nie zmieniła się. Ich wspólną cechą jest poszukiwanie rozwiązania zadania w wyniku ewolucji. Ciągłe, ewolucyjne przybliżanie i/lub oddalanie się do/od rozwiązania optymalnego zwykle pozwala osiągnąć sukces. Ostateczny wynik jest efektem realizacji wielu iteracji algorytmu poszukiwania. Nie wynika on, tak jak w podejściu klasycznym, z wykonania w określonej kolejności formalnie zdefiniowanych rachunków. Ta własność obliczeń ewolucyjnych uznawana jest zarówno za wadę jak i zaletę. Wadą jest wówczas, gdy nadrzędną sprawą jest wyznaczenie rozwiązania zadania w ściśle określonym czasie. Pod tym względem *EA* nie mogą konkurować z metodami formalnymi. Zaletą jest wtedy, gdy poszukuje się rozwiązania zadania, którego model jest słabo określony lub całkowicie nieznany. W obliczeniach ewolucyjnych poszukiwane parametry zadania koduje się w postaci wektora zmiennych. Zależnie od algorytmu, przyjmuje się kodowanie binarne, kodowanie rzeczywiste oraz kodowanie w postaci drzew. Innym sposobem kodowania jest kodowanie logarymiczne. W sposób istotny skraca ono długość przetwarzanych ciągów binarnych, ale do samej idei obliczeń nie wnosi nic nowego. Przykłady kodowania zawarto w [17] – [19]. Każdemu z kodowanych parametrów narzuca się możliwy zakres zmienności. Po zakończeniu kodowania uzyskuje się uporządkowany ciąg zmiennych (*genotyp*).

Zmienne te początkowo przyjmują wartości nadawane im przez losowanie, tworząc tym samym fenotyp. Fenotyp podlega przetwarzaniu w procesie sztucznej ewolucji. Proces ten jest tym sprawniejszy, im lepiej zrealizowany jest generator zmiennej losowej. Za lepszy generator przyjmuje się ten, który charakteryzuje się dłuższym okresem powtarzania generowanych ciągów liczb. Od jakości generatora zależy zdolność eksploracji przestrzeni parametrów, a tym samym możliwość wyznaczania jakościowo lepszych rozwiązań zadania. Rozwiązania te są uzyskiwane w realizowanym cyklicznie procesie poszukiwania. Wyznaczane wartości parametrów w pojedynczym cyklu modyfikowane są przez operatory genetyczne: krzyżowanie i/lub mutację. Ideę działania operatorów genetycznych przedstawiono w [7] – [9], [18], [19]. Rozwiązanie otrzymane w sposób ewolucyjny ocenia się funkcją przystosowania. Dobrze określona funkcja przystosowania jednoznacznie wskazuje rozwiązanie bliższe optymalnemu. Ostatnim elementem pojedynczego cyklu poszukiwania jest selekcja osobników. W algorytmie ewolucyjnym jej zadanie sprowadza się do ograniczenia zbioru (populacji) wygenerowanych rozwiązań do liczebności pierwotnie zakładanej. W *GA*, rys. 1, stosuje się ją także w celu wskazania osobników przeznaczonych do reprodukcji.



Rys. 1. Podstawowy algorytm genetyczny

3. Koncepcja prognozowania tendencji zmian kursu akcji

3.1. Poszukiwanie ewolucyjne a rozwiązanie optymalne

Obliczenia ewolucyjne służą do wyznaczania optimum globalnego. Polegają na tworzeniu kolekcji rozwiązań podlegających ocenie. Do kolejnych ewolucji przechodzą na ogół osobniki (instancje) najbardziej perspektywiczne, to znaczy o najlepszych wartościach funkcji przystosowania.

Zastosowanie obliczeń ewolucyjnych do wyznaczenia rozwiązania zadania zawsze wiąże się z wątpliwościami. Najczęściej dotyczą one sposobu kodowania parametrów oraz metody przeszukiwania przestrzeni dopuszczalnych rozwiązań. Główne pytanie, które się wówczas pojawia, brzmi: czy EA wyznaczą rozwiązanie optymalne? Ponieważ brakuje formalnego dowodu, odpowiedzi poszukiwano na drodze eksperymentu. Przyjęto w nim, że V określony przez $[v_1, \dots, v_{n-1}, v_n]$ reprezentuje n dyskretnych znanych wartości kursu akcji przedsiębiorstwa uzyskanych na kolejnych SGPW. P zapisany jako $[p_1, \dots, p_{n-1}, p_n]$ jest ciągiem obserwacji odpowiadających wartościom kursu akcji. Poprawność uzyskiwanych rozwiązań badano *ex post* zgodnie z formułą

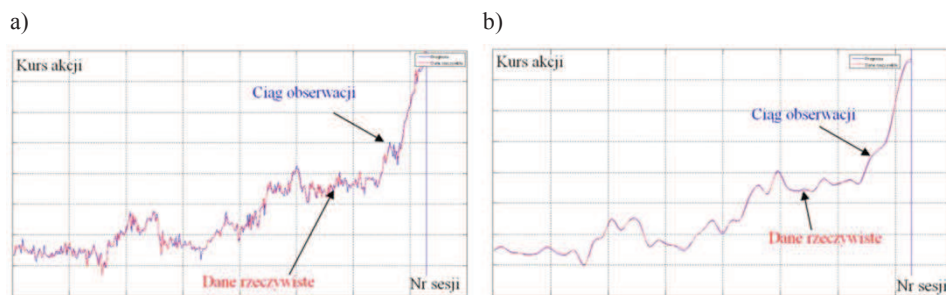
$$O(V, P) = \sum_{i=1}^n |v_i - p_i|. \quad (1)$$

Poszukiwanie ewolucyjne kończono, gdy spełniona była zależność

$$O(V, P) \leq e_{rr}, \quad (2)$$

gdzie e_{rr} – dopuszczalny błąd wyznaczanych wartości obserwacji. Za rozwiązanie optymalne przyjęto takie P , które spełnia (2) dla $e_{rr} = 0$. Rezultat

przeprowadzonego doświadczenia zilustrowano na rys. 2. Przypadek pokazany na rys. 2 dotyczy przedsiębiorstwa Żywiec. Do obliczeń przyjęto 365 notowań kursu akcji z kolejnych *SGPW*. Uzyskana wartość funkcji przystosowania $O(V, P)$ dla 2000 iteracji ewolucyjnego algorytmu poszukiwania przy rozmiarze populacji równym 500 wyniosła 0,93653.




Rys. 2. Wartości kursu akcji: wynik obliczeń (a), wynik filtracji dolnoprzepustowej (b)

Oznacza to, że średnio błąd wyznaczania wartości kursu na poszczególne dni wyniósł 0,0025 zł. Podobieństwo rzeczywistej krzywej kursu i wyznaczonej na podstawie uzyskanych dyskretnych wartości zakodowanych w genotypie jest lepiej widoczne po wykonaniu filtracji dolnoprzepustowej, na przykład przy użyciu falek, rys. 2b.

3.2. Prognozowanie tendencji zmian kursu akcji

Określając prognozę, przyjęto założenie, że reguły wpływające na kurs akcji w równym stopniu działają w przeszłości i przyszłości. Przyjęty w 3.1 ciąg obserwacji P określono przez $[p_1, \dots, p_{(n-t)}, \dots, p_n]$, gdzie $(n - t)$ – liczba obserwacji podlegających ocenie. Ostatnich t obserwacji nie podlega ocenie i stanowi wyznaczaną prognozę, rys. 3.



Rys. 3. Graficzna reprezentacja przyjętych założeń

W badaniach zastosowano strategię ewolucyjną. Algorytm ten operuje na danych kodowanych w postaci liczb rzeczywistych, co znacznie upraszcza jego

wykorzystanie. Znane wartości kursu akcji zakodowano w postaci struktury zgodnej z opisem wektora V . Wartości elementów wektora P wylosowano z R^+ . W praktyce, podczas działania strategii ewolucyjnej w użyciu było k instancji ciągu P . To oznacza, że algorytm operował na populacji dopuszczalnych rozwiązań $\{P^1, \dots, P^k\}$. W każdej iteracji algorytmu ewolucyjnego instancje ciągu wraz z zawartą w nich prognozą podlegały operacjom krzyżowania, mutacji, selekcji oraz ocenie.

Mutacja zmienia wartość i -tego elementu wektora P^l zgodnie z wzorem:

$$M(p_i^l, x_i, d, g) = (1 - a(x_i))p_i^l + a(x_i)f(d, g), \quad (3)$$

gdzie:

$$a(x) = \begin{cases} 1 & \text{gdy } x \geq T_M \\ 0 & \text{w przeciwnym przypadku} \end{cases} \quad (4)$$

p_i^l – i -ty element wektora P^l ;

$f(d, g)$ – wartość losowa należąca do przedziału $[d, g]$;

x_i – zmienna losowa przyjmująca wartości z $[0, 1]$ określająca prawdopodobieństwo mutacji i -tego elementu wektora P^l ;

d, g – wartość dolnego i górnego progu takie, że $d \geq 0$ i $g > d$;

T_M – przyjęty arbitralnie próg mutacji, np. 0,01.

Czynność tę przeprowadzano dla każdej pary (l, i) , gdzie $l \in \{1, \dots, k\}$, $i \in \{1, \dots, n\}$, jednoznacznie określającej modyfikowany element p_i^l w wektorze $P^l \in \{P^1, \dots, P^k\}$.

Krzyżowanie zmienia wartość i -tego elementu wektora P^l na i -tą wartość wektora P^r , gdzie r – zmienna losowa taka, że $r \in \{1, \dots, k\} \setminus \{l\}$. Zmianę dokonuje się zgodnie z formułą:

$$K(p_i^l, p_i^r, y_i) = (1 - b(y_i))p_i^l + b(y_i)p_i^r, \quad (5)$$

gdzie:

$$b(y) = \begin{cases} 1 & \text{gdy } y \geq T_K \\ 0 & \text{w przeciwnym przypadku} \end{cases} \quad (6)$$

p_i^l – i -ty element wektora P^l , którego wartość zmieniana jest podczas operacji krzyżowania;

p_i^r – i -ty element wylosowanego wektora P^r ;

y_i – zmienna losowa przyjmująca wartości z przedziału $[0, 1]$ określająca prawdopodobieństwo krzyżowania i -tego elementu wektora P^l ;

T_K – przyjęty arbitralnie próg krzyżowania, np. 0,5.

Krzyżowanie przeprowadzano dla każdego i -tego elementu wektora P^l i każdego $l \in \{1, \dots, k\}$, dla którego losowano $r \in \{1, \dots, k\} \setminus \{l\}$.

Wektory $\{P^1, \dots, P^k\}$ podlegały ciągłej ocenie. Celem oceny było wskazanie ciągów najlepiej dopasowanych do wzorca zakodowanego w V . W przyjętej realizacji im lepsze dopasowanie, tym mniejsza była wartość funkcji przystosowania, $O^l(V, P^l)$. Wartość funkcji wyznaczano z wzoru:

$$O^l(V, P^l) = \sum_{i=1}^{n-t} |v_i - p_i^l|. \quad (7)$$

Obliczenia przeprowadzano dla każdego $l \in \{1, \dots, k\}$.

Elementy v_i , dla których $(n-t) < i \leq n$, służyły do sprawdzenia poprawności wyznaczonej obserwacji zmian kursu akcji. Pozostałych składowych wektora użyto do konstrukcji warunku stopu algorytmu. Obliczenia ewolucyjne kończono, gdy spełniona była zależność

$$\min_{l \in \{1, \dots, k\}} O^l(V, P^l) \leq \epsilon_{rr}, \quad (8)$$

gdzie ϵ_{rr} – dopuszczalny błąd w ocenianej części instancji ciągu.

W przypadku niespełnienia warunku (8) poszukiwanie ewolucyjne zatrzymywano po wykonaniu założonej liczby iteracji (*NumOfGen*).

4. Wyniki badań prognozowania tendencji zmian kursów akcji

W eksperymentach wykorzystano metodę z punktu trzeciego. Dla każdego z badanych przedsiębiorstw wytworzono plik zawierający 365 notowań wartości kursów akcji. Następnie przyjęto zakres prognozy $t = 30$. Wartość tę ustalono arbitralnie. Prognozowanie prowadzono w oparciu o wektor 335 obserwacji. Dla nich w każdej iteracji algorytmu wyznaczano wartość funkcji przystosowania. Pozostałe trzydzieści wartości były przetwarzane, ale nie podlegały ocenie. Wykonanie założonej liczby iteracji algorytmu ewolucyjnego lub spełnienie warunku stopu (8) kończyło poszukiwanie rozwiązania. Za rezultat poszukiwania przyjmowano tego osobnika, który charakteryzował się najmniejszą wartością funkcji przystosowania. Tendencje zmian kursu akcji wyznaczano po wykonaniu filtracji dolnoprzepustowej (falkowej).

Podczas eksperymentów zbadano działanie algorytmu dla trzynastu wybranych przedsiębiorstw notowanych na Giełdzie Papierów Wartościowych w Warszawie. Wyznaczanie prognozy przeprowadzono dla dwóch ustawień.

	Pierwsze	Drugie	Interpretacja
ZakProgn	30	30	zakres prognozy
NumOfGen	2000	2000	liczba iteracji algorytmu
PopSize	100	500	rozmiar populacji rodzicielskiej
MustStay	10	10	liczba pozostających osobników

Otrzymane rezultaty eksperymentów zawarto w tab. 1 i 2. Do zapisu uzyskanych wyników przyjęto notację:

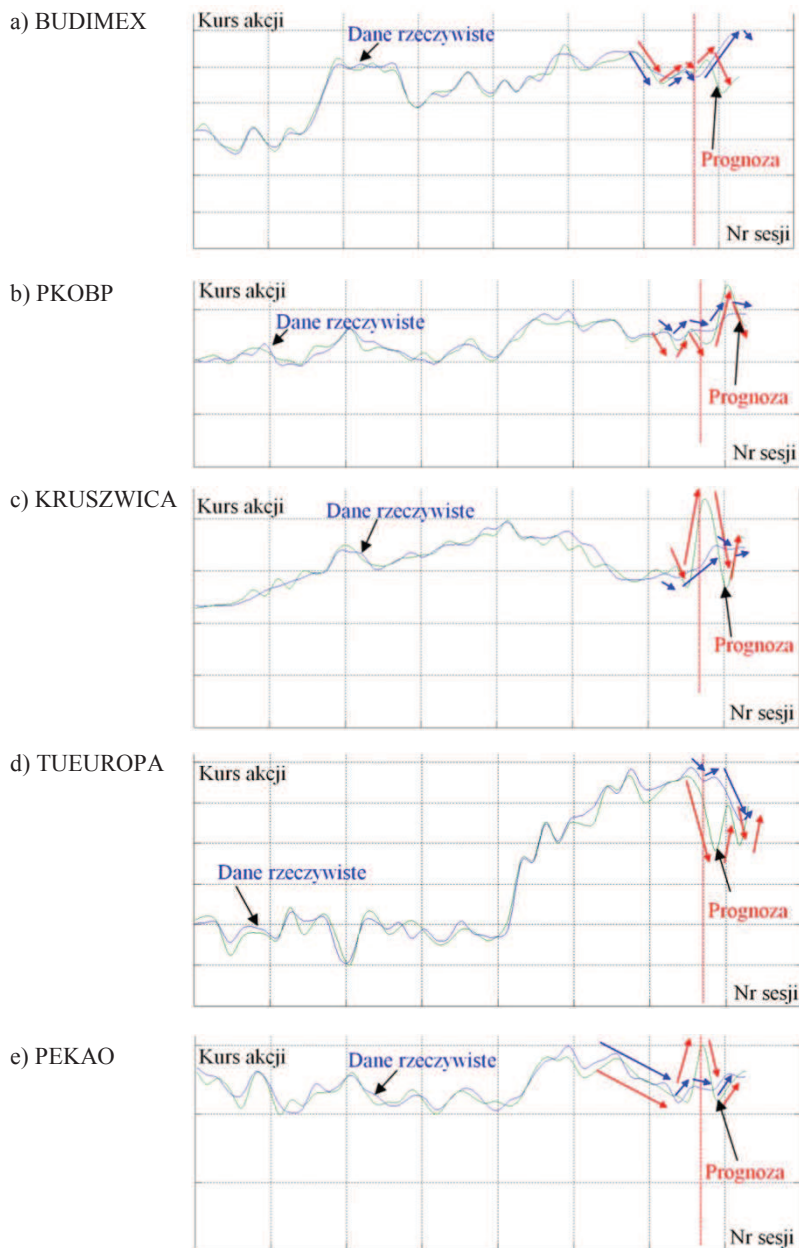
- „+” – wzrostowa tendencja zmian kursu akcji;
- „-” – opadająca tendencja zmian kursu akcji;
- „o” – pełzająca tendencja zmian kursu akcji;
- „bd” – brak możliwości bezspornego ustalenia tendencji zmian.

Tab. 1. Rezultaty badań dla pierwszego wariantu ustawień

Przedsiębiorstwo	Dane	Tendencje zmian kursu akcji					Wart. funk. oceny
BUDIMEX	Dane rzeczywiste	-	+	-	+	-	9.25518
	Prognoza	-	+	-	+	-	
DĘBICA	Dane rzeczywiste	-	+	-			8.73705
	Prognoza	-	+	-			
KERNEL	Dane rzeczywiste	-	+	-	+	bd	8.28348
	Prognoza	-	+	-	+	-	
KRUSZWICA	Dane rzeczywiste	-	+	-	+	bd	9.16093
	Prognoza	-	+	-	+	-	
LPP	Dane rzeczywiste	-	+	-	+	bd	8.72301
	Prognoza	-	+	-	+	-	
MILLENNIUM	Dane rzeczywiste	-	+	-	+	-	10.27560
	Prognoza	-	+	-	+	+	
PEKAO	Dane rzeczywiste	-	+	-	+	-	9.80174
	Prognoza	-	+	-	+	bd	
PKNORLEN	Dane rzeczywiste	-	+	+	+	-	9.46177
	Prognoza	-	+	-	+	-	
PKOBP	Dane rzeczywiste	-	+	-	+	-	9.60661
	Prognoza	-	+	-	+	-	
POLLENAE	Dane rzeczywiste	-	o	-	-		10.10590
	Prognoza	-	+	-	+		
TUEUROPA	Dane rzeczywiste	-	+	-	+		8.97822
	Prognoza	-	+	-	+		
UNICREDIT	Dane rzeczywiste	-	+	-	bd	bd	8.74521
	Prognoza	-	+	-	+	-	
ŻYWIEC	Dane rzeczywiste	+	+	+	o		9.24193
	Prognoza	-	+	-	+		

Spośród trzynastu przedsiębiorstw uwzględnianych w eksperymentach, dziewięć charakteryzowało się w pełni poprawnie wyznaczonymi tendencjami zmian kursu akcji. W jednym wyznaczona prognoza był całkowicie błędna.

W jednym przypadku uzyskana prognoza była częściowo poprawna, a w pozostałych dwóch zanotowano błąd wyznaczania prognozy w jednym z pięciu jej segmentów. Wybrane przypadki wyznaczonych tendencji zmian kursu akcji zaprezentowano na rys. 4.



Rys. 4. Wyznaczone tendencje zmian kursu akcji

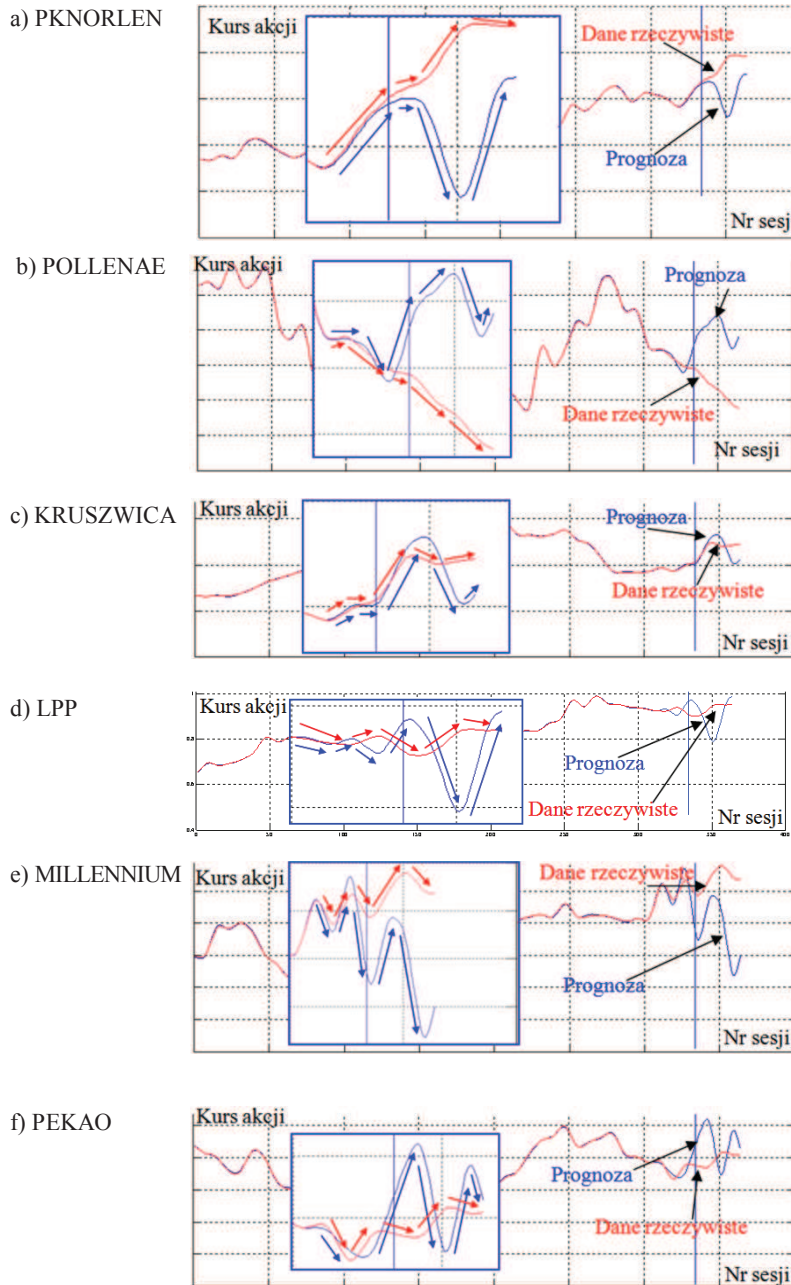
Eksperyment wykonano powtórnie, zwiększając rozmiar populacji rodzicielskiej ze 100 do 500. Zmiana wielkości populacji, przy zachowaniu liczby iteracji algorytmu poszukiwania, na ogół skutkuje eksploracją większego obszaru przestrzeni dopuszczalnych rozwiązań. Uzyskane wyniki podano w tab. 2. Z badania wynika, że cztery prognozy były w całości poprawne. W pięciu przypadkach zanotowano błąd wyznaczenia prognozy jednego z pięciu jej segmentów. W trzech przypadkach błąd prognozy dotyczył dwóch segmentów.

Tab. 2. Rezultaty badań dla drugiego wariantu ustawień

Przedsiębiorstwo	Dane	Tendencje zmian kursu akcji					Wart. funk. oceny
		+	-	+	o	bd	
BUDIMEX	Dane rzeczywiste	+	-	+	o	bd	1.15160
	Prognoza	+	-	+	-	+	
DĘBICA	Dane rzeczywiste	-	+	-	+		1.06056
	Prognoza	-	+	-	-		
KERNEL	Dane rzeczywiste	+	-	o	o		1.13140
	Prognoza	+	-	+	-		
KRUSZWICA	Dane rzeczywiste	+	o	+	-	+	1.11601
	Prognoza	+	o	+	-	+	
LPP	Dane rzeczywiste	-	+	-	+	-	1.16080
	Prognoza	-	+	-	+	-	
MILLENNIUM	Dane rzeczywiste	-	+	-	+	-	1.23650
	Prognoza	-	+	-	+	-	
PEKAO	Dane rzeczywiste	-	+	-	+	-	1.10676
	Prognoza	-	+	-	+	-	
PKNORLEN	Dane rzeczywiste	+	+	+	-	-	1.07989
	Prognoza	+	o	-	+	o	
PKOBP	Dane rzeczywiste	+	-	+	-	-	1.16597
	Prognoza	+	+	+	-	+	
POLLENAE	Dane rzeczywiste	+	-	-	-	-	1.10966
	Prognoza	+	-	+	+	-	
TUEUROPA	Dane rzeczywiste	+	-	+	-	+	1.13091
	Prognoza	+	-	+	+	+	
UNICREDIT	Dane rzeczywiste	+	-	+	-	-	1.09189
	Prognoza	+	-	+	-	+	
ŻYWIEC	Dane rzeczywiste	+	-	+	o	+	1.14520
	Prognoza	+	-	+	+	+	

Zwiększenie populacji rodzicielskiej korzystnie wpłynęło na wartości funkcji oceny. Wszystkie wartości uzyskano niższe niż poprzednio. Świadczy to o lepszym dopasowaniu się wyznaczanych ciągów obserwacji do wzorca w jego ocenianym odcinku. Zauważono także, że w przypadku uzyskania właściwej prognozy poprawia się również jej dopasowanie. Oceniając całościowo, należy uznać, że w porównaniu do wyników pierwszego eksperymentu mniejsza liczba przedsiębiorstw miała w pełni poprawnie wyznaczone tendencje zmian kursu akcji. Przykłady błędnie (a i b) oraz poprawnie (c do f) wyznaczonych tendencji

zmian kursu akcji podano na rys. 5. Przeprowadzone eksperymenty uzupełniono o badanie powtarzalności wyznaczonych tendencji zmian.

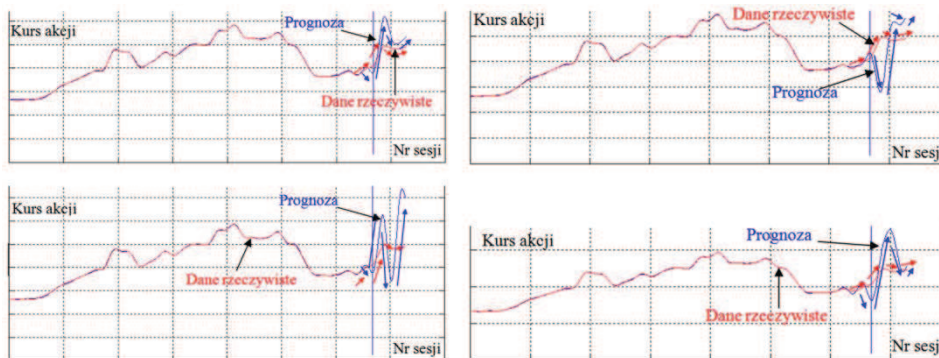


Rys. 5. Wyznaczone tendencje zmiany kursu akcji

Eksperyment wykonano z uwagi na panujące powszechnie przekonanie, że obliczenia ewolucyjne przy każdym uruchomieniu algorytmu generują inne rozwiązanie. Podczas badań dla wybranego przedsiębiorstwa czterokrotnie uruchomiono wytworzony skrypt. Poszczególne próby przeprowadzono przy tych samych nastawach obliczeń ewolucyjnych. Zmianie podlegała jedynie wartość początkowa generatora zmiennej losowej. Do przeprowadzenia testu wybrano drugi wariant ustawień. Uzyskane wyniki badań podano w tab. 3.

Tab. 3. Rezultat badania powtarzalności wyznaczania zmian kursu

Firma	Dane	Tendencja zmian kursu akcji			
		+	+	-	+
ŻYWIEC I	Dane rzeczywiste	+	+	-	+
	Prognoza	-	+	-	+
ŻYWIEC II	Dane rzeczywiste	+	+	-	+
	Prognoza	-	+	-	+
ŻYWIEC III	Dane rzeczywiste	+	+	-	+
	Prognoza	-	+	-	+
ŻYWIEC IV	Dane rzeczywiste	+	+	-	+
	Prognoza	-	+	-	+



Rys. 6. Badanie powtarzalności wyznaczania zmian kursu akcji przedsiębiorstwa ŻYWIEC

Na podstawie uzyskanych wyników można stwierdzić, że obawy dotyczące braku powtarzalności generowanych rozwiązań okazały się niesłuszne. Sposób dochodzenia do ostatecznego wyniku mógł być oczywiście różny. Niemniej jednak przyjęta konstrukcja algorytmu zapewniła powtarzalność wyznaczanych rozwiązań. Wygenerowana prognoza, choć częściowo błędna, pozostawała taka przy kolejnych uruchomieniach algorytmu. Jest to zdecydowanie pozytywny objaw. Najgorszym rezultatem byłaby ciągła zmienność prognozowanych zmian kursu akcji. Taki wynik uniemożliwiłby jednoznaczne wnioskowanie. W konsekwencji podjęcie decyzji kupna lub sprzedaży akcji przedsiębiorstwa byłoby utrudnione. Uzyskane prognozy zilustrowano na rys. 6.

5. Wnioski

W artykule przedstawiono zastosowanie obliczeń ewolucyjnych do prognozowania tendencji zmian kursów akcji. Prognozowanie przeprowadzono, wykorzystując dane archiwalne oraz reguły przetwarzania wynikające z użycia strategii ewolucyjnej. Poprawność określania prognozy zbadano dla trzynastu przedsiębiorstw notowanych na *GPW*. Wykonane eksperymenty dowiodły, że przyjęta konstrukcja genotypu była poprawna. Dzięki temu strategia ewolucyjna mogła wyznaczać obserwacje równe lub bliskie znanym wartościom kursu akcji. Następnie genotyp zmodyfikowano w celu wyznaczenia prognozy. Reguły przetwarzania pozostawiono bez zmian. Podczas badań zauważono, że zmodyfikowana postać genotypu nie pozwala właściwie wyznaczać wartości notowań akcji. Jest to jednak zrozumiałe, ponieważ w tym aspekcie działanie strategii ewolucyjnej nie podlegało żadnej kontroli. Pomimo to, w większości przypadków (rzędu 70%) strategia ewolucyjna poprawnie prognozowała tendencje zmian kursu akcji.

Literatura

- [1] ABOUELDAHAB T., FAKHRELDIN M., *Prediction of Stock Market Indices using Hybrid Genetic Algorithm/ Particle Swarm Optimization with Perturbation Term*, International Conference on swarm intelligence, ICSI 2011.
- [2] BLEDSOE W.W., *The use of biological concepts in the analytical study of systems*, ORSA – TIMS National Meeting, 1961.
- [3] BOX G. E. P., *Evolutionary operation: A method for increasing industrial productivity*, „Journal of Royal Statistical Society C”, Vol. 6, No. 2, 1957, pp. 81 – 101.
- [4] BRABAZON A., O'NEILL M., MARINGE D. G., *Natural Computing in Computational Finance*, Tom 3. Springer-Verlag, Berlin Heidelberg 2010, pp. 85 – 100.
- [5] BREMERMAN H.J., *Optimization through evolution and recombination*, Self-Organizing Systems 1962, edited M.C. Yovitts et al., Spartan Books, Washington, D.C. pp. 93 – 106.
- [6] EIBEN E.A., VAN KEMENADE C.H.M., KOK J.N., *Orgy in the Computer: Multi – Parent Reproduction in Genetic Algorithm*, Third European Conference on Artificial Life, 1995.
- [7] FOGEL L.J., OWENS A.J., WALSH M.J., *Artificial Intelligence Through Simulated Evolution*, Wiley J., 1966.
- [8] FRASER A.S., *Simulation of genetic systems by automatic digital computers*, „Australian Journal of Biological Science”, 1957.
- [9] FRIEDMAN G.J., *Digital simulation of an evolutionary process*, „General Systems Yearbook”, Vol. 4, 1959, pp. 171 – 184.

- [10] HAUPT R., HAUPT S.E., *Practical Genetic Algorithms*, John Wiley & Sons, 1998.
- [11] HOLLAND J.H., *Adaptation in Natural and Artificial Systems*, The University of Michigan Press, 1975.
- [12] MARKOWSKA-KACZMAR U., KWASNICKA H., SZCZEPKOWSKI M., *Genetic Algorithm as a Tool for Stock Market Modelling*, Artificial Intelligence and Soft Computing – ICAISC 2008 Lecture Notes in Computer Science, Vol. 5097/2008, pp. 450 – 459, DOI: 10.1007/978-3-540-69731-2_44
- [13] MURPHY J., *Analiza techniczna rynków finansowych*, WIG PRESS, 1999.
- [14] MURAWSKA M., *Zarządzanie strategiczne niematerialnymi zasobami przedsiębiorstwa*, Nowe Trendy w Naukach Ekonomicznych i Zarządzaniu, Fundacja Promocji i Akredytacji Kierunków Ekonomicznych, 2008.
- [15] MURAWSKA M., *Kształtowanie cen akcji przedsiębiorstw notowanych na Gieldzie Papierów Wartościowych w Warszawie – perspektywa minionego dwudziestolecia*, Prace i Materiały Wydziału Zarządzania Uniwersytetu Gdańskiego, ISBN/ISSN: ISSN 1732-1565, 2011, pp. 181 – 193.
- [16] MURAWSKA M., *Realizacja strategii specjalizacji i dywersyfikacji przez spółki publiczne notowane na Gieldzie Papierów Wartościowych w Warszawie*, „Nowoczesne Systemy Zarządzania”, 2011, pp. 110 – 118.
- [17] MURAWSKI K., *Segmentacja obrazów rastrowych z wykorzystaniem strategii ewolucyjnych*, praca doktorska, WAT, 2001.
- [18] MURAWSKI K., *Obliczenia ewolucyjne – geneza i zastosowanie*, „Biuletyn IAIr”, 15/2001, str. 55 – 104.
- [19] REACHENBERG I., *Evolutionstrategie: optimierung technischer systeme nach prinzipien der biologischen evolution*. Frommann – Holzboog, 1973.
- [20] *Analiza techniczna – wprowadzenie*, Seria: Reuters, Wydawnictwo Wolters Kluwer Polska – Oficyna, 2001, ISBN: 83-88597-13-2.
- [21] SAM M., MANI G., „*Financial forecasting using genetic algorithms*”, Applied Artificial Intelligence, Vol. 10, No. 6, 1996, pp. 543 – 565.
- [22] *Wavelet Toolbox User's Guide*, The Mathworks Inc., 2008.
- [23] WITKOWSKA D., *Application of artificial neural networks to stock price prediction*, „Journal of Applied Computer Science”, Vol. 7, No. 1, 1999, pp. 79 – 89.
- [24] YOVITS G.T., JACOBI G.T., GOLDSTEIN G.D. (ED.), *Self-organizing systems*, Spartan Books, 1962, pp. 93 – 106.

Application of evolutionary strategies in predicting stock price trends

ABSTRACT: The trend of stock price is determined in the paper using an evolutionary strategy and historical quotations. On the basis of experiments it has been shown that the evolutionary strategy enables correct matching of coded in a genotype sought sequence of shares price to the value of listed securities. The genotype has been modified to allow determination of the future exchange rate trends (forecasts). The method of forecasting was verified for thirteen selected companies whose data was obtained from the Stock Exchange in Warsaw.

KEYWORDS: evolutionary computation, trend line market, prediction

Praca wpłynęła do redakcji: 21.11.11