

Paweł Skrzyński\*

## **Predykcja stóp procentowych na pieniężnym rynku międzybankowym oraz rynku kredytowym z wykorzystaniem sieci neuronowych**

### **1. Opis problemu**

W oparciu o dane dotyczące wielkości stóp WIBOR (*Warsaw Interbank Offered Rate*) oraz kredytowej (średnia stopa kredytowa dwudziestu największych banków komercyjnych w Polsce) oraz innych wielkości ekonomicznych, które nazwano zmiennymi wspomagającymi, w kolejnych miesiącach od stycznia 1995 do grudnia 2004 utworzono perceptron wielowarstwowy mogący prognozować wartość tych stóp w następnych okresach. Celem badań było znalezienie takiej sieci, która zadowalająco będzie pozwalała na predykcję wartości stóp procentowych, przy jej możliwie najmniejszej architekturze.

Przeprowadzono szereg eksperymentów porównujących różne algorytmy uczenia:

- algorytm wstecznej propagacji błędów wraz z metodą gradientów sprzężonych,
- strategię ewolucyjną.

### **2. Metodologia**


Analizowane dane podzielono na dwie serie:

- 1) dane uczące, wartości od stycznia 1995 do grudnia 2002 roku,
- 2) dane testowe, wartości od stycznia 2003 do marca 2004 roku.

Pierwsze eksperymenty polegały na uczeniu za pomocą samych wartości przeszłych. Przyjęto, że perceptron miał cztery wejścia, na które podawano wartości stóp procentowych w punktach czasowych:  $t-6$ ,  $t-3$ ,  $t-1$ , oraz  $t$ . W kolejnych doświadczeniach uczenie było wspomagane dodatkowymi wskaźnikami ekonomicznymi wykazującymi dobrą korelację ze stopami WIBOR oraz kredytową. Zatem na kolejne trzy wejścia podawano wartości wybranych wskaźników w chwili  $t$ . Za każdym razem predykcja była przeprowadzana dla punktu  $t+1$ .

---

\* Katedra Automatyki, Akademia Górniczo-Hutnicza, Kraków



**Rys. 1.** Architektura wykorzystywanej sieci neuronowej oraz wartości podawane na wejście

Sieć (rys. 1) była uczona za pomocą danych uczących. Po nauce perceptron był egzaminowany za pomocą danych testowych i wyznaczany był błąd średniokwadratowy RMS.

Wielkości, którymi wspomagane było uczenie, to:

- cel inflacyjny,
- stopa lombardowa.

Współczynniki korelacji pomiędzy zmiennymi ekonomicznymi zebrane zostały w tabeli 1. Do badań wykorzystano sieć trójwarstwową z 16 neuronami o charakterystyce funkcji logistycznej w warstwie ukrytej.

**Tabela 1**  
Współczynniki korelacji pomiędzy wskaźnikami ekonomicznymi wykorzystywanymi w eksperymentach

|                 | WIBOR | Stopa kredytowa | Cel inflacyjny | Stopa lombardowa |
|-----------------|-------|-----------------|----------------|------------------|
| WIBOR           | 1     | 0,972           | 0,892          | 0,985            |
| Stopa kredytowa | 0,972 | 1               | 0,918          | 0,979            |

## 2.1. Metody uczenia

W badaniach długość ciągu uczącego wynosiła 77 punktów. W uczeniu za pomocą strategii ewolucyjnej przyjęto liczebność populacji 18 osobników oraz następujący sposób kodowania sieci neuronowej do chromosomu (kodowanie za pomocą liczb rzeczywistych): do chromosomu po kolei wchodzi kolejne wagi neuronów z każdej warstwy.

W modelu strategii ewolucyjnej jako zastosowano osobniki z puli potomnej (jej liczebność oznaczono przez  $\mu$ ) rywalizowały z osobnikami z puli rodzicielskiej (jej liczebność oznaczono przez  $\lambda$ , gdzie  $\mu = 7 * \lambda$ ) – do następnej generacji wchodziło  $\lambda$  najlepszych osobników. Dodatkowo dla każdego osobnika konieczne było pamiętanie zmiennych związanych ze strategią (odpowiadających odchyleniom standardowym potrzebnym przy realizacji mutacji).

Poniższy pseudokod przedstawia szkielet algorytmu, którym się posługiwano:

```

t := 0;
initialize P(0) := {a1(0), a2(0), ..., aμ(0)}
  where ak(j) = (xi, sigi);
evaluate P(0);
while t < max_iteration do begin
  recombine a'k(t) := r(P(t)) ∀ k ∈ {1, ..., λ};
  mutate a''k(t) := m(a'k(t));
  evaluate P'(t) := {a1''(t), ..., aλ''(t)};
  ({f(x1''(t)), ..., f(xλ''(t))});
  select P(t+1) from P(t) ∪ P'(t);
  t := t+1;

```

Używany operator rekombinacji jest krzyżowaniem arytmetycznym: z dwóch rodziców tworzony jest tylko jeden potomek (zmienne związane ze strategią są również krzyżowane w klasyczny jednopunktowy sposób). Szerszego opisu wymaga operator mutacji, który jest realizowany następująco

$$m(a_k) = a'_k = (x', \sigma')$$

przy czym:

$$\sigma'_i = \sigma_i * \exp(\tau_0 * \Delta\sigma_0) * \exp(\tau * \Delta\sigma_i)$$

$$x'_i = x_i + \sigma'_i$$

*i* – aktualna iteracja

Stałe ustalone są następująco:  $\tau_0 = 1/\sqrt{2 * \sqrt{n}}$ ,  $\tau = 1/\sqrt{2n}$  (gdzie *n* jest długością chromosomu). Parametr  $\Delta\sigma_0$  jest taki sam dla wszystkich *i* oraz jest losowany z rozkładem normalnym z odchyleniem standardowym równym jeden, natomiast parametr  $\Delta\sigma_i$  również jest losowany z rozkładem normalnym z odchyleniem standardowym równym jeden dla każdego *i* indywidualnie.

Drugą wykorzystywaną metodą było połączenie metod wstecznej propagacji błędów oraz metody gradientów sprzężonych. Metoda wstecznej propagacji błędów w pierwszym rzędzie na podstawie sygnałów wyjściowych i wzorcowych oblicza błędy w warstwie wyjściowej, następnie w warstwie poprzedzającej i dalej aż do warstwy wejściowej. Podczas procesu uczenia sieci neuronowej zastosowano stałe współczynniki uczenia (0,1) i bezwładności (0,3). Metoda gradientów sprzężonych polega na modyfikacji wag jednocześnie w trakcie realizacji jednej epoki. W trakcie stosowania tego algorytmu na powierzchni błędu wyznaczana jest w każdej epoce średnia wartość gradientu, będąca podstawą modyfikacji wag przeprowadzanej w końcowej fazie każdej epoki. W trakcie swojego działania algorytm ten przeprowadza poszukiwania liniowe minimalnego błędu wzdłuż wybranych kierunków na powierzchni błędu. Po wyszukaniu minimalnego błędu, realizowane są następne poszukiwania (jedno w jednej epoce) przeprowadzane wzdłuż prostych, które sprzężone są z wcześniej wybranym kierunkiem. Metody te są dostępne w pakiecie *Statistica* w dodatku *Sieci Neuronowe*.

### 3. Wyniki

W tabelach 2 oraz 3 zebrano wyniki dla strategii ewolucyjnej, natomiast w tabelach 4 i 5 dla połączonych metod wstecznej propagacji błędów Zole metodą gradientów sprzężonych.

**Tabela 2**  
Predykcja WIBOR – wyniki, strategia ewolucyjna

| Dodatkowe wejście          | RMS, dane testowe | RMS, dane uczące | Korelacja, dane testowe | Korelacja, dane uczące |
|----------------------------|-------------------|------------------|-------------------------|------------------------|
| Brak dodatkowych zmiennych | 1,382             | 0,761            | 0,784                   | 0,990                  |
| Stopa kredytowa            | 0,642             | 0,712            | 0,878                   | 0,991                  |
| Stopa lombardowa           | 0,466             | 0,770            | 0,855                   | 0,990                  |
| Cel inflacyjny             | 0,373             | 0,741            | 0,934                   | 0,990                  |
| Wszystkie                  | 0,840             | 0,798            | 0,931                   | 0,989                  |

**Tabela 3**  
Predykcja stopy kredytowej – wyniki, strategia ewolucyjna

| Dodatkowe wejście          | RMS, dane testowe | RMS, dane uczące | Korelacja, dane testowe | Korelacja, dane uczące |
|----------------------------|-------------------|------------------|-------------------------|------------------------|
| Brak dodatkowych zmiennych | 2,985             | 0,574            | 0,660                   | 0,990                  |
| WIBOR                      | 0,622             | 0,454            | 0,805                   | 0,996                  |
| Stopa lombardowa           | 1,365             | 0,528            | 0,391                   | 0,994                  |
| Cel inflacyjny             | 0,714             | 0,575            | 0,850                   | 0,992                  |
| Wszystkie                  | 1,037             | 0,483            | 0,737                   | 0,995                  |

**Tabela 4**  
Predykcja stopy WIBOR – wyniki, wsteczna propagacja błędów z gradientami sprzężonymi


| Dodatkowe wejście          | RMS, dane testowe | RMS, dane uczące | Korelacja, dane testowe | Korelacja, dane uczące |
|----------------------------|-------------------|------------------|-------------------------|------------------------|
| Brak dodatkowych zmiennych | 0,389             | 0,833            | 0,945                   | 0,988                  |
| Stopa kredytowa            | 0,390             | 0,823            | 0,889                   | 0,988                  |
| Stopa lombardowa           | 0,351             | 0,833            | 0,939                   | 0,988                  |
| Cel inflacyjny             | 0,772             | 0,765            | 0,903                   | 0,990                  |
| Wszystkie                  | 1,400             | 0,725            | 0,809                   | 0,991                  |

**Tabela 5**


Predykcja stopy kredytowej – wyniki, wsteczna propagacja błędów z gradientami sprzężonymi

| Dodatkowe wejście          | RMS, dane testowe | RMS, dane uczące | Korelacja, dane testowe | Korelacja, dane uczące |
|----------------------------|-------------------|------------------|-------------------------|------------------------|
| Brak dodatkowych zmiennych | 0,706             | 0,652            | 0,852                   | 0,990                  |
| WIBOR                      | 0,996             | 0,501            | 0,853                   | 0,994                  |
| Stopa lombardowa           | 0,689             | 0,536            | 0,838                   | 0,993                  |
| Cel inflacyjny             | 0,964             | 0,596            | 0,839                   | 0,991                  |
| Wszystkie                  | 0,904             | 0,489            | 0,833                   | 0,994                  |

Jak widać na rysunkach 2 oraz 3, użycie do predykcji dodatkowych zmiennych ekonomicznych pozwoliło na znaczną poprawę rezultatów. We wszystkich doświadczeniach wartość współczynnika korelacji jest większa od 0,8 — model można zatem uznać za dobry. Najlepszy rezultat w predykcji WIBOR został uzyskany przy wspomaganiu uczenia wartością wskaźnika cel inflacyjny – RMS jest bardzo niski, natomiast współczynnik korelacji większy od 0,9 – dla predykcji WIBOR. Dla predykcji stopy kredytowej współczynnik ten jest większy od 0,85 (jest to drugi co do jakości rezultat). Najlepszy wynik dla predykcji stopy kredytowej został uzyskany przy wspomaganiu uczenia stopą WIBOR. WIBOR w przypadku danych uczących odwzorowanie sygnału przez sieć jest bardzo dobre – niski RMS oraz współczynnik korelacji większy od 0,98 w każdym przypadku.

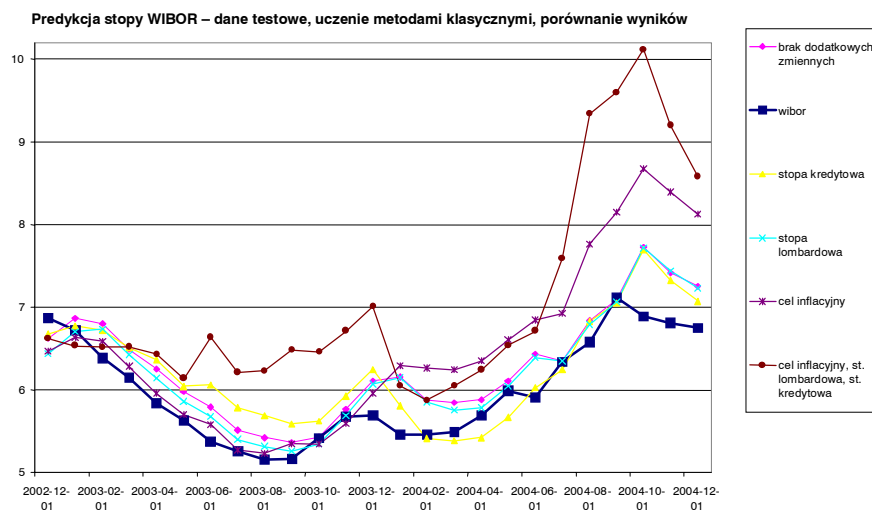


**Rys. 2.** Predykcja stopy WIBOR, porównanie rezultatów dla strategii ewolucyjnej, dane testowe

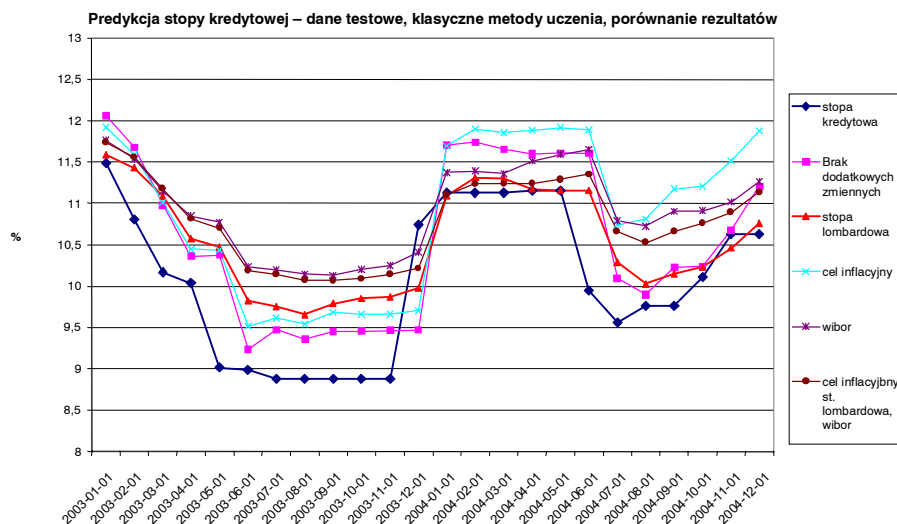


**Rys. 3.** Predykcja stopy kredytowej, porównanie rezultatów dla strategii ewolucyjnej, dane testowe

Jak widać na rysunkach 4 i 5, również w przypadku klasycznych metod nauczania sieci przyniosło poprawę rezultatów. Podobnie jak dla strategii ewolucyjnej współczynnik korelacji dla danych testowych w każdym przypadku jest większy od 0,8, co oznacza dobre dopasowanie modelu. Zarówno dla predykcji stopy WIBOR, jak i stopy kredytowej najlepszy rezultat został osiągnięty, gdy nauczanie było wspomagane wartościami stopy lombardowej w odpowiednich okresach. RMS jest niski, a współczynnik korelacji większy od 0,85 dla stopy kredytowej oraz 0,9 dla stopy WIBOR.



**Rys. 4.** Predykcja stopy WIBOR, porównanie rezultatów dla metody wstecznej propagacji błędów z gradientami sprzężonymi, dane testowe



Rys. 5. Predykcja stopy kredytowej, porównanie rezultatów dla metody wstecznej propagacji błędów z gradientami sprzężonymi, dane testowe

#### 4. Podsumowanie i wnioski

Przeprowadzone eksperymenty dowodzą, iż z powodzeniem można stosować sieci neuronowe jako narzędzie do predykcji wskaźników ekonomicznych. Dla każdego eksperymentu uzyskany RMS dla danych testowych był satysfakcjonująco niski przy współczynniku korelacji wynoszącym przynajmniej 0,8. Minimalnie lepsze rezultaty uzyskano dla predykcji stopy WIBOR — RMS poniżej 0,4 i współczynnik korelacji ponad 0,9. Zastosowane algorytmy uczenia: klasyczny oparty o wsteczną propagację błędów razem z metodą gradientów sprzężonych oraz nowe podejście oparte o strategię ewolucyjną dały porównywalne rezultaty. Klasyczne metody okazały się minimalnie lepsze dla predykcji stopy WIBOR, natomiast w przypadku stopy kredytowej strategia ewolucyjna dała lepsze rezultaty.

Zastosowanie metod bazujących na sztucznej inteligencji może zatem stanowić dobre uzupełnienie dla dotychczasowych metod predykcji wartości wskaźników ekonomicznych.

#### Literatura

- [1] Back T., Gunter R., Schwefel H.P.: *Evolutionary Programming and Evolution Strategies: Similarities and Differences*. 1992
- [2] Back T.: *Evolutionary Algorithms in Theory and Practice: Evolution Strategies, Evolutionary Programming, Genetic Algorithms*. Oxford, Oxford University Press 1996
- [3] Bednarczyk J.: *Stopy procentowe a gospodarka. Eseje z teorii i polityki stóp pieniężnych*. Radom, Wydawnictwo Politechniki Radomskiej 2004
- [4] Szydło S.: *Stopy Procentowe w gospodarce polskiej*. Kraków, Oficyna Wydawnicza Test 2002
- [5] Tadeusiewicz R.: *Sieci neuronowe*. Wyd. 2, Warszawa, Warszawska Oficyna Wydawnicza RM 1993

