

## Zastosowanie sieci neuronowej do wyznaczania wektora prędkości przepływu gazów

KATARZYNA SOCHA, PAWEŁ LIGEZA, ELŻBIETA POLESZCZYK

*Instytut Mechaniki Górotworu PAN, ul. Reymonta 27; 30-059 Kraków*

### Streszczenie

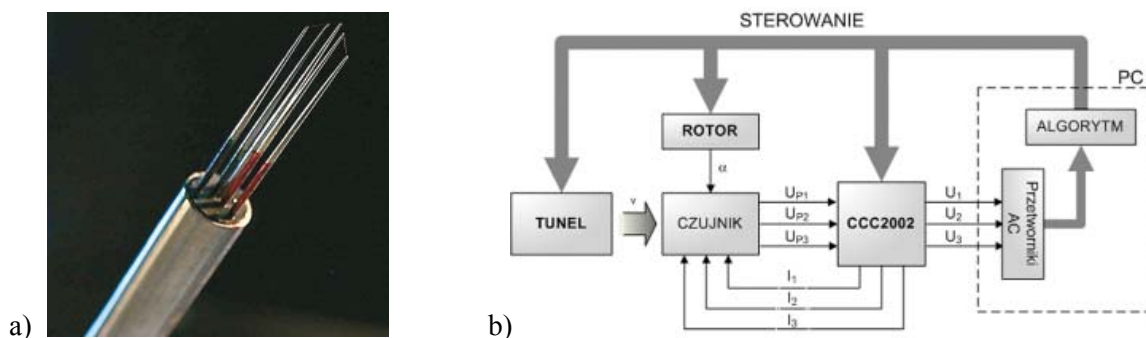
Do pomiaru wektora prędkości w przepływach przestrzennych gazów wykorzystuje się sondę trójwłókową. Dzięki ortogonalnemu rozmieszczeniu włókien względem siebie można związać z nimi kartezjański układ współrzędnych. W pracy przedstawiono analizę możliwości wykorzystania sztucznej sieci neuronowej do pomiaru wektora prędkości gazu. Do wyznaczania składowych wektora prędkości z sygnałów pomiarowych zastosowano sieć neuronową z dwoma warstwami ukrytymi. Struktura sieci została dobrana eksperymentalnie. Otrzymane za pomocą sieci neuronowej wyniki porównano z metodą opartą na równaniach Kinga oraz Jorgensena.

**Słowa kluczowe:** termooanemometria, wektor prędkości, sztuczna sieć neuronowa

### 1. Wprowadzenie

Od wielu lat Pracownia Metrologii Przepływów IMG PAN zajmuje się budową nowych przyrządów i opracowywaniem nowych metod pomiaru wektora prędkości przepływu gazu (Kiełbasa, 1998, 2001, Poleszczyk, 2002; Socha, 2009). W pracy zostanie przedstawiona możliwość zastosowania sztucznej sieci neuronowej do wyznaczania wektora prędkości. Ze względu na charakterystykę tej metody nie trzeba określać algorytmu przeliczającego zmierzone napięcia na wektor prędkości. Istotne jest natomiast określenie struktury sieci neuronowej oraz odpowiednie dobranie algorytmu uczącego.


Zaproponowaną metodę pomiaru wektora prędkości testowano na stanowisku pomiarowym (rys. 1b), w którego skład wchodziła sonda pomiarowa, układ stałotemperaturowy CCC2002 (Ligeza, 2003), dwie karty szybkich przetworników analogowo-cyfrowych (Gawor, 1999), tunel aerodynamiczny oraz rotor umożliwiający obrót sondy wokół osi. Całość sterowana była za pomocą komputera ze specjalistycznym oprogramowaniem (Ciombor, 2004; Gawor i Socha, 2004). Do pomiaru wektora prędkości w przepływach przestrzennych jest dedykowana sonda trójwłókowa (rys. 1a) (Poleszczyk, 2002). W sondzie tej włókna anemometryczne umieszczone są prostopadle względem siebie, w ten sposób, że tworzą krawędzie sześcianu.



Rys. 1. a) termooanemometryczna sonda trójwłókowa; b) schemat stanowiska pomiarowego

## 2. Sztuczna sieć neuronowa

Sztuczne sieci neuronowe są to algorytmy, których działanie wzorowane jest na działaniu sieci biologicznych komórek nerwowych. Podstawowym elementem budowy sieci neuronowej jest neuron, będący uproszczonym modelem komórki nerwowej. Każdy neuron posiada wiele wejść ( $x_1, x_2, \dots, x_N$ ) i tylko jedno wyjście ( $y$ ). Z każdym wejściem związany jest parametr, tzw. waga  $w_i$ , określający moc sygnału wejściowego. Pobudzenie neuronu stanowi suma iloczynu sygnałów wejściowych i ich wag. Często do odpowiedzi neuronu dodaje się dodatkowy składnik, tzw. *bias*. Jest to wartość progowa, umożliwiającą wytworzenie sygnału wyjściowego przez neuron. Sygnał wyjściowy z neuronu określany jest za pomocą funkcji aktywacji  $\varphi$ , której argumentem jest zsumowany iloczyn sygnałów i wag. Funkcją aktywacji może być funkcja skokowa, funkcja sigmoidalna, funkcja ciągła (Tadeusiewicz, 1993).




Rys. 2. Schemat sztucznego neuronu

Pojedyncze neurony łączone są ze sobą tworząc sieć neuronową. Wyróżnia się sieci jednokierunkowe, w których przepływ informacji odbywa się w jednym kierunku, od od wejścia ( $X_1, X_2, \dots, X_N$ ) do wyjścia ( $Y_1, Y_2, \dots, Y_M$ ) oraz sieci ze sprzężeniem zwrotnym.

Najczęściej wykorzystywaną strukturą sieci neuronowej jest sieć wielowarstwowa. Neurony między warstwami połączone są na zasadzie „każdy z każdym”. Wyróżnia się następujące warstwy:

- *warstwa wejściowa* – służąca do wprowadzania sygnałów wejściowych do sieci,
- *warstwy ukryte* – służące do przetwarzania informacji,
- *warstwa wyjściowa* – wyprowadzająca sygnały wyjściowe na zewnątrz.



Rys. 3. Sztuczna sieć wielowarstwowa jednokierunkowa

Ważnym elementem przy projektowaniu struktury sieci neuronowej jest określenie liczby warstw ukrytych oraz liczby neuronów w poszczególnych warstwach. Liczba elementów warstwy wejściowej jest związana z liczbą sygnałów wejściowych. Podobnie jest w warstwie wyjściowej, liczba neuronów zależy od liczby poszukiwanych sygnałów wyjściowych. Pozostałe parametry, czyli liczba warstw ukrytych oraz liczba elementów w poszczególnych warstwach ukrytych zależą od stopnia skomplikowania problemu. Za


mała liczba zarówno warstw ukrytych, jak i neuronów uniemożliwia prawidłowe działanie sieci. Natomiast zbyt duża liczba warstw prowadzi do pogorszenia procesu uczenia. Najczęściej przyjmuje się nie więcej niż dwie warstwy ukryte. Z kolei zbyt duża liczba neuronów w warstwach ukrytych może prowadzić do zjawiska „uczenia się na pamięć”. Sieć wówczas potrafi prawidłowo rozwiązać zadanie tylko dla przypadków, w jakich była uczona, nie potrafi uogólnić zdobytej wiedzy i zastosować jej na większym zbiorze testowym.

Istotną cechą sieci neuronowej jest możliwość uczenia się. Polega ono na modyfikowaniu wartości wag poszczególnych połączeń pomiędzy neuronami, w taki sposób, by zwiększyć efektywność sieci przy rozwiązywaniu zadań określonego typu. Istnieją dwa sposoby uczenia sieci: z nauczycielem oraz bez nauczyciela. Pierwszy polega na podawaniu sieci wyników jakie powinna uzyskać dla konkretnego zestawu sygnałów wejściowych. Taki zestaw złożony z wartości wejść oraz wyjść, wykorzystywany w procesie uczenia nazywany jest *ciągą uczącym*. W przypadku uczenia bez nauczyciela sieć nie otrzymuje informacji o rozwiązaniach. Sama ma wychwycić reguły występujące w podawanych jej sygnałach wejściowych. Taki sposób uczenia wykorzystuje się przy klasyfikacji, rozpoznawaniu obrazów.

Dzięki zdolności uczenia się, sztuczna sieć neuronowa nie wymaga programowania ani konstruowania algorytmów do rozwiązywania badanego problemu. Zaletą sieci neuronowej jest też równoległe wykonywanie obliczeń, co wiąże się ze zwiększeniem szybkości działania w porównaniu z obliczeniami wykonywanymi sekwencyjnie (Tadeusiewicz, 1998).

### 3. Wyznaczanie wektora prędkości przepływu

W celu przetestowania możliwości zastosowania sieci neuronowej do pomiaru wektora prędkości przeprowadzono dwa niezależne eksperymenty dla prędkości z zakresu od  $0.5$  do  $10 \text{ ms}^{-1}$ . Sonda obracana była wokół osi osadki co  $5^\circ$  (rys. 4). W położeniu początkowym sonda ustawiona była w ten sposób, że jedno z włókien było ustawione równoległe do przepływu przy prostokątnym ustawieniu dwóch pozostałych. Pierwsza seria pomiarowa posłużyła do uczenia sieci, a druga do jej testowania.



Rys. 4. Schemat pozycjonowania sondy podczas eksperymentów

Sieć zaimplementowano za pomocą środowiska *Matlab* i biblioteki *Neural Network*. Strukturę sieci do wyznaczania wektora prędkości przepływu wybrano eksperymentalnie. Ponieważ na wejście sieci podawane są napięcia pomiarowe pochodzące z sondy musi posiadać ona trzy wejścia. W warstwie wyjściowej znajdują się trzy neurony z liniową funkcją aktywacji. Każdy z neuronów związany jest z jedną składową wektora prędkości. Zastosowano dwie warstwy ukryte z neuronami o sigmoidalnej funkcji aktywacji. Liczbę neuronów w pierwszej warstwie ukrytej dobierano z zakresu od 5 do 50, a w drugiej od 2 do 20.

Do uczenia sieci zastosowano algorytm wstecznej propagacji błędów. Do obliczenia wartości wyjść sieci w ciągu uczącym wyznaczono teoretyczny rozkład wektora prędkości  $v^t$  związany z włóknami sondy o następującej postaci (Ligeża i Socha, 2007):

$$\begin{aligned}
v'_x &= \frac{\sqrt{2}}{4} v |\sin 2\beta \cdot (1 - \cos \alpha) + 2 \sin \beta \cdot \sin \alpha|, \\
v'_y &= \frac{\sqrt{2}}{4} v |\sin 2\beta \cdot (\cos \alpha - 1) + 2 \sin \beta \cdot \sin \alpha|, \\
v'_z &= \frac{1}{2} v |\sin 2\beta \cdot (1 + \cos \alpha)|
\end{aligned} \tag{1}$$

gdzie:

$\beta = 54,74^\circ$  – kąt między włóknami a osią czujnika, będący kątem rozwarcia stożka,

$\alpha$  – kąt obrotu sondy względem jej osi,

$v$  – wartość prędkości zadanego przepływu.

Wyboru struktury sieci dokonywano na podstawie wskaźnika jakości o następującej postaci:

$$Q = \frac{1}{3N} \sum_{i=1}^3 \sum_{j=1}^N \left( \frac{v^o(i, j) - v^t(i, j)}{|v^t(j)|} \right)^2 \tag{2}$$

gdzie:

$v^o(i, j)$  –  $i$ -ta składowa wektora prędkości wyznaczona za pomocą sieci neuronowej dla  $j$ -tego ustawienia sondy,

$v^t(i, j)$  –  $i$ -ta składowa teoretycznego wektora prędkości dla  $j$ -tego ustawienia sondy,

$N$  – liczba wykonanych pomiarów do wzorcowania.

Najmniejszą wartość wskaźnika  $Q$  otrzymano dla sieci, która miała 40 neuronów w pierwszej warstwie ukrytej i 20 neuronów w drugiej. Taka sieć została przetestowana dla drugiego zestawu pomiarów. Otrzymane z danych „testowych” składowe wektora prędkości przedstawiono na rysunku 5.

#### 4. Ocena działania sieci neuronowej

Do porównania otrzymanych za pomocą sztucznej sieci neuronowej wyników użyto metody jednokrokowej (Ligęza i Socha, 2007). Składowe wektora prędkości w tej metodzie wyznacza się z następujących zależności:

$$\begin{aligned}
v_x^o &= \sqrt{b_{1x}(U_1^2 - a_{1x})^{2n_{1x}} + b_{2x}(U_2^2 - a_{2x})^{2n_{2x}} + b_{3x}(U_3^2 - a_{3x})^{2n_{3x}}}, \\
v_y^o &= \sqrt{b_{1y}(U_1^2 - a_{1y})^{2n_{1y}} + b_{2y}(U_2^2 - a_{2y})^{2n_{2y}} + b_{3y}(U_3^2 - a_{3y})^{2n_{3y}}}, \\
v_z^o &= \sqrt{b_{1z}(U_1^2 - a_{1z})^{2n_{1z}} + b_{2z}(U_2^2 - a_{2z})^{2n_{2z}} + b_{3z}(U_3^2 - a_{3z})^{2n_{3z}}}
\end{aligned} \tag{3}$$

gdzie:

$U$  – napięcie pomiarowe,

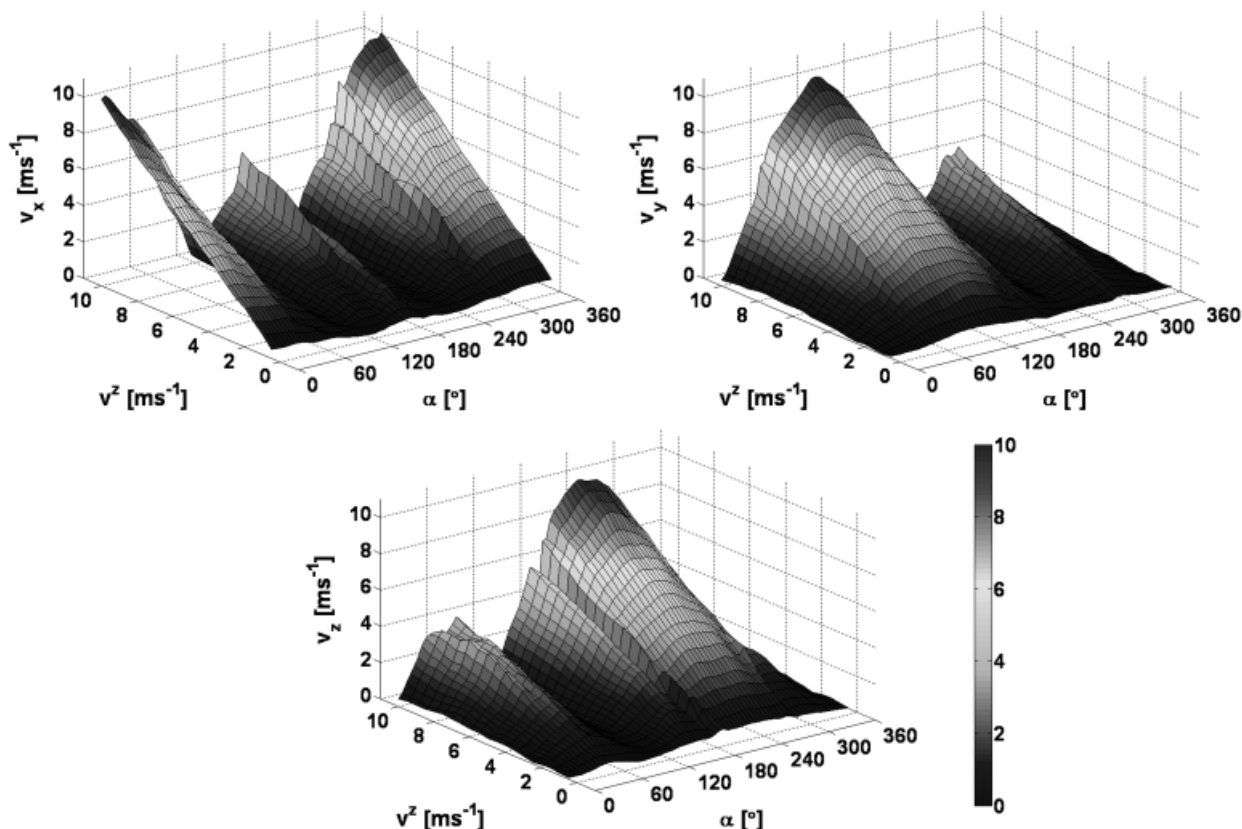
$a, b, n$  – współczynniki wyznaczone podczas wzorcowania sondy.

Na podstawie danych pomiarowych z pierwszej serii wywzorcowano sondę trójwłóknową dla metody jednokrokowej. Dopasowania danych pomiarowych do teoretycznego wektora prędkości (1) dokonano w środowisku *Matlab* za pomocą funkcji *fminsearch*.

W celu porównania obu metod wyznaczania wektora prędkości policzono wskaźnik jakości (2) dla danych ze zbioru testowego:

- dla sieci neuronowej:  $Q = 0.0043$ ,
- dla metody jednokrokowej:  $Q = 0.0189$ .

Na podstawie wskaźnika (2) można uznać, że za pomocą sztucznej sieci neuronowej dokładniej wyznaczono wektor prędkości. Na rysunku 6 pokazano wyznaczone dla obu metod składowe wektora prędkości oraz wektor teoretyczny dla obrotu sondy wokół osi i zadananej prędkości w tunelu  $5 \text{ ms}^{-1}$ . Składowe wyznaczone za pomocą sieci neuronowej lepiej dopasowały się do wartości teoretycznej niż w metodzie jednokrokowej. Dla kątów z zakresu od  $30-90^\circ$ ,  $150-210^\circ$  oraz  $270-330^\circ$  otrzymano największe rozbieżności



Rys. 5. Składowe wektora prędkości wyznaczone za pomocą sztucznej sieci neuronowej dla przepływu z zakresu od 0.5 do 10 ms<sup>-1</sup>

od wartości teoretycznej dla obu metod. Ma to związek z konstrukcją sondy i przysłanianiem włókien. Dla metody jednokrokowej przy położeniu prostopadłym włókna powstają „strefy zerowe” (składowa  $v_y$ : kąty 220-240°, składowa  $v_z$ : kąty 115-150° oraz 330-360°). W obszarach tych składowe osiągają wartości urojone, które są automatycznie zerowane przez algorytm. Ten efekt nie występuje dla wyników otrzymanych za pomocą sieci neuronowej.

Do oceny działania sieci neuronowej wyznaczono procentowy błąd względny dla modułu oraz składowych wektora prędkości o następującej postaci:

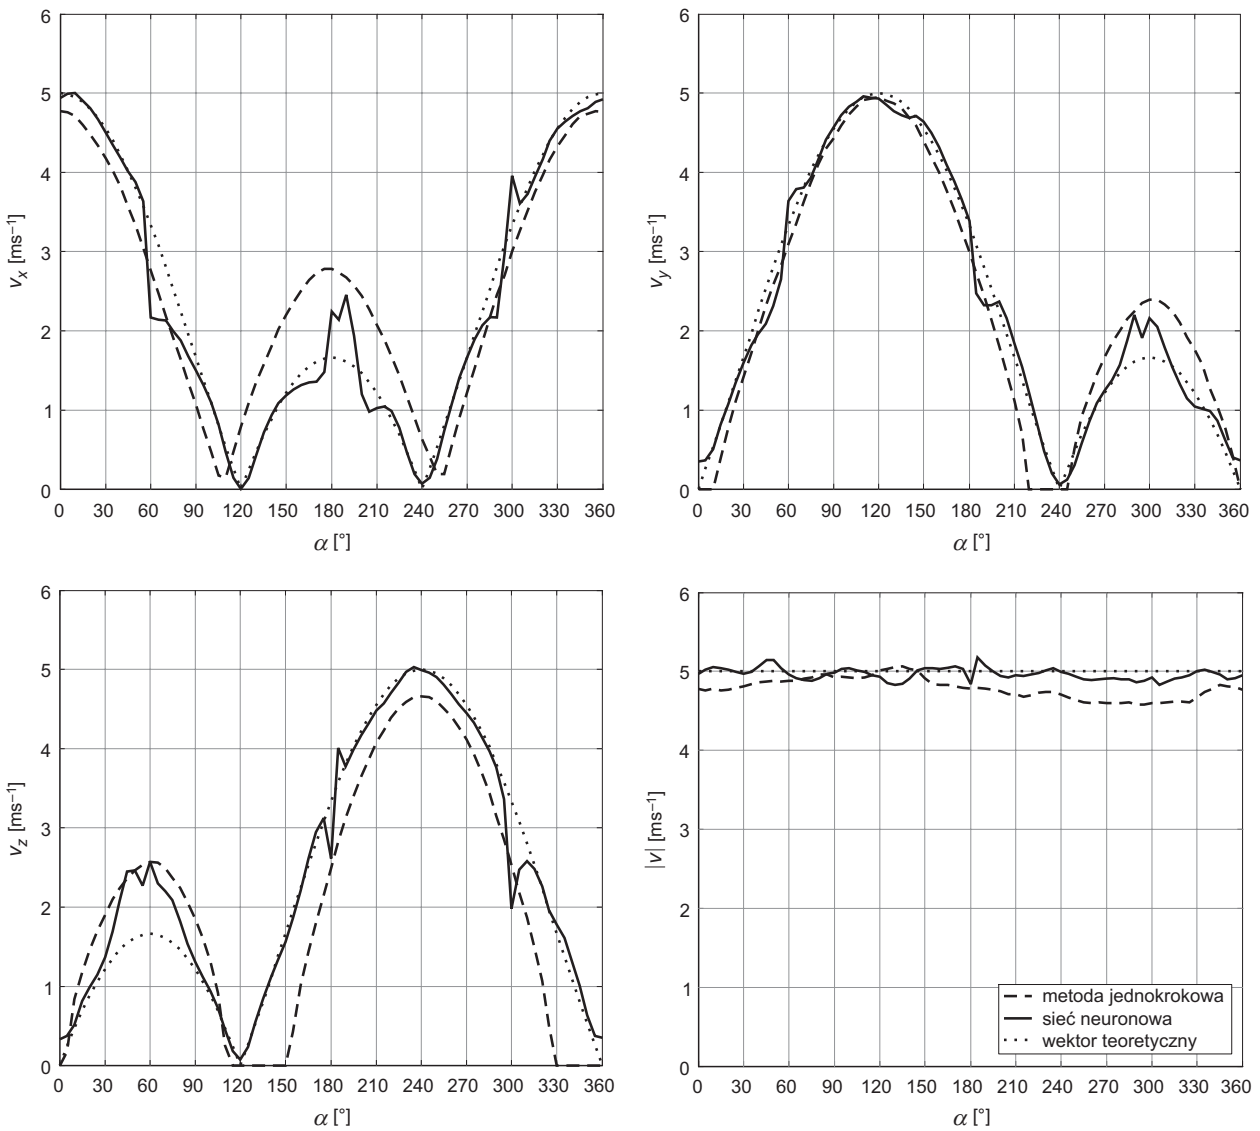
$$\Delta w = \frac{w^o - w^t}{|v^z|} \cdot 100\% \quad (4)$$

gdzie:

- $w^o$  – wyznaczona za pomocą sieci neuronowej składowa wektora prędkości lub jego moduł,
- $w^t$  – teoretyczna wartość składowej wektora prędkości lub teoretyczna wartość modułu,
- $v^z$  – prędkość zadawana w tunelu aerodynamicznym.

Wyznaczone dla obu metod błędy względne przedstawiono na rysunku 7. W lewej kolumnie umieszczono wyniki dla sieci neuronowej, a w prawej dla metody jednokrokowej. Dla obu metod maksymalne wartości błędu dopasowania występują dla małych prędkości. Największe błędy dla metody jednokrokowej otrzymano dla tych położenia włókna, w których znajduje się ono w pobliżu położenia prostopadłego względem przepływu („strefy zerowe”). Duże błędy dla tej metody otrzymuje się również między dwoma położeniami prostopadłymi włókna. Wartość składowych jest wówczas zawyżana, w pozostałych położeniach przyjmuje wartości niższe od spodziewanych.

W przypadku sieci neuronowej nie ma błędów pochodzących od „stref zerowych”. Sieć otrzymuje najgorsze wyniki między położeniami prostopadłymi poszczególnych włókien. Największe błędy występują w okolicach kątów 60°, 180° oraz 300°. Ponieważ sieć jednocześnie działa na wszystkich napięciach błędy te przenoszą się na wszystkie składowe.



Rys. 6. Składowe oraz moduł wektora prędkości wyznaczone za pomocą sieci neuronowej (linia ciągła) i metody jednokrokowej (linia przerywana) dla przepływu  $5 \text{ ms}^{-1}$ . Linią kropkowaną zaznaczono teoretyczny rozkład wektora prędkości

W celu sprawdzenia jaki wpływ na otrzymane wyniki ma prędkość mierzonego przepływu obliczono dla obu metod błąd średniokwadratowy w funkcji zadawanej prędkości o następującej postaci:

$$\varepsilon_w = \frac{1}{N} \sum_{i=1}^N \left( \frac{w^o(i) - w^t(i)}{|v^t|} \right)^2 \quad (5)$$

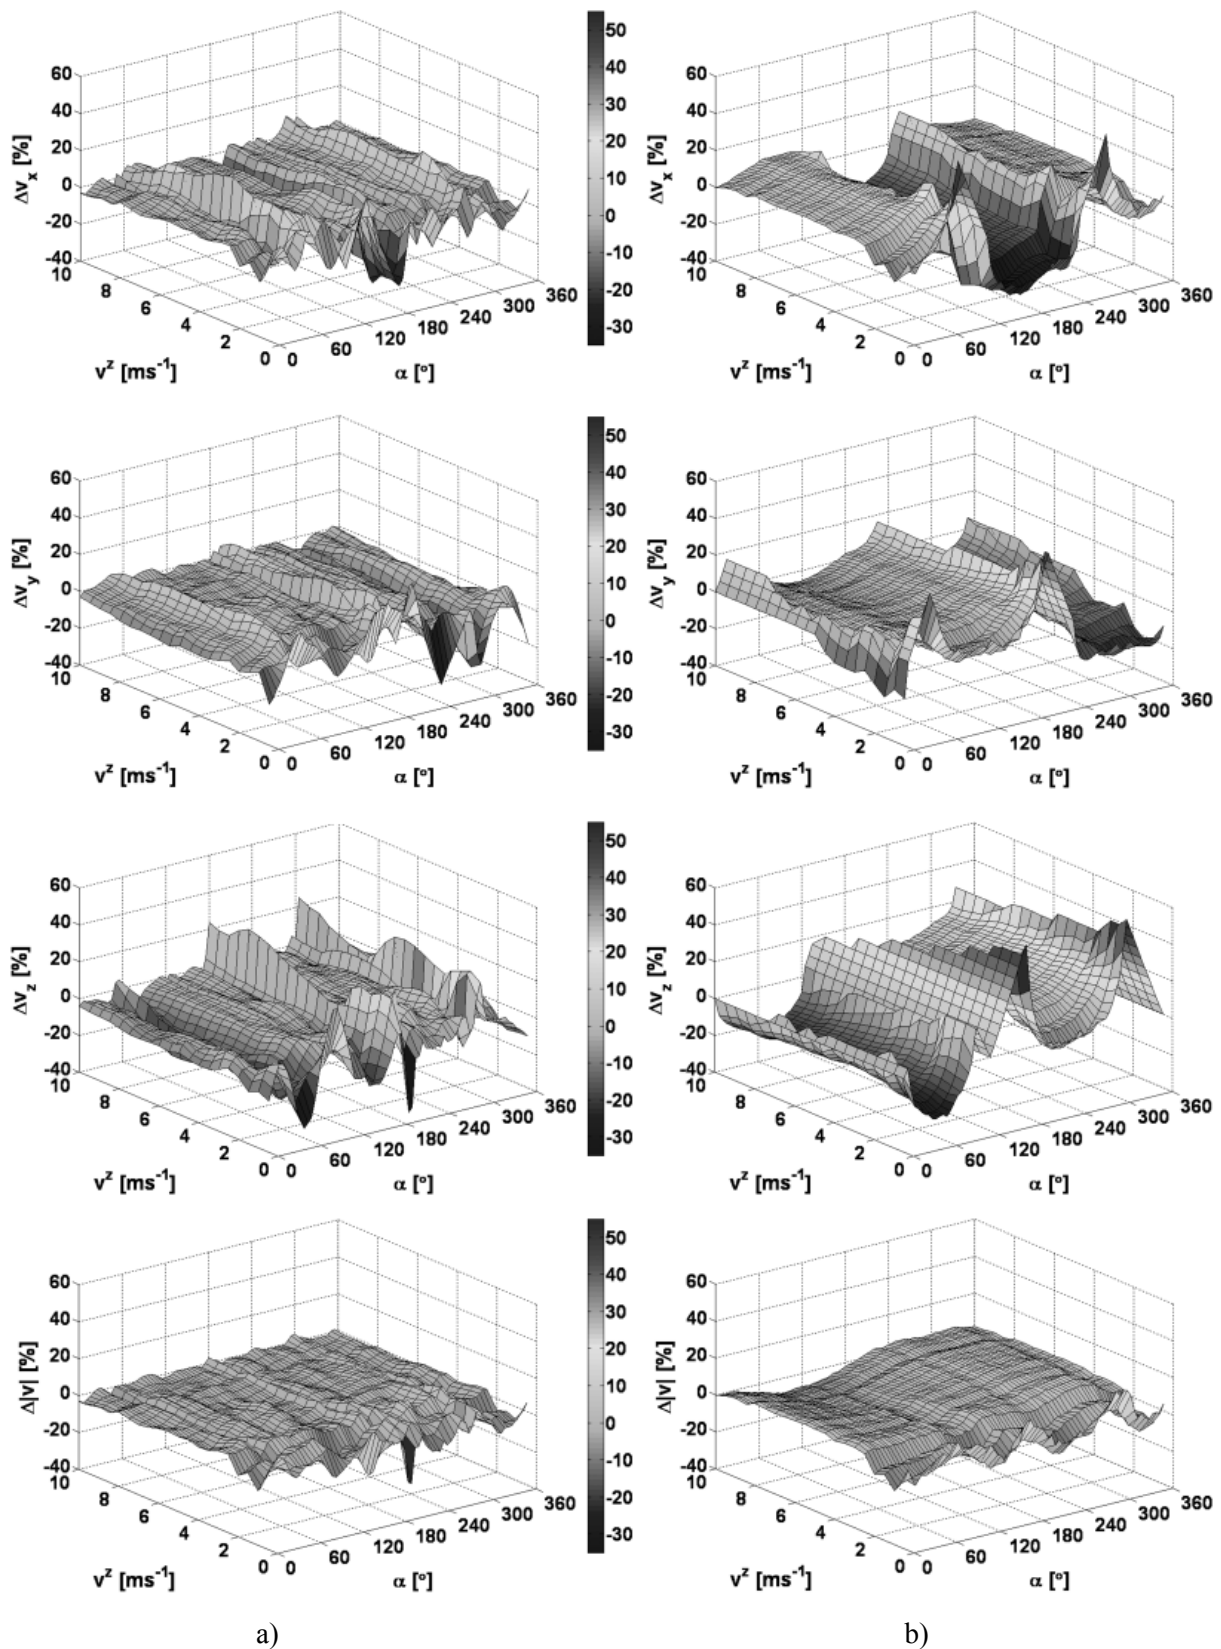
gdzie:

- $N$  – liczba pomiarów wykonanych dla każdej z prędkości,
- $w$  – składowa wektora prędkości lub jego moduł.

Błąd średniokwadratowy przedstawiono na rysunku 8. W przypadku obu metod największe wartości błędu otrzymano dla małych prędkości. Wzrost wartości zadawanej prędkości powoduje spadek wartości błędu. Dla sieci neuronowej otrzymano mniejsze wartości błędu niż dla metody jednokrokowej. Dla wartości prędkości powyżej  $3 \text{ ms}^{-1}$  błąd nieznacznie maleje.

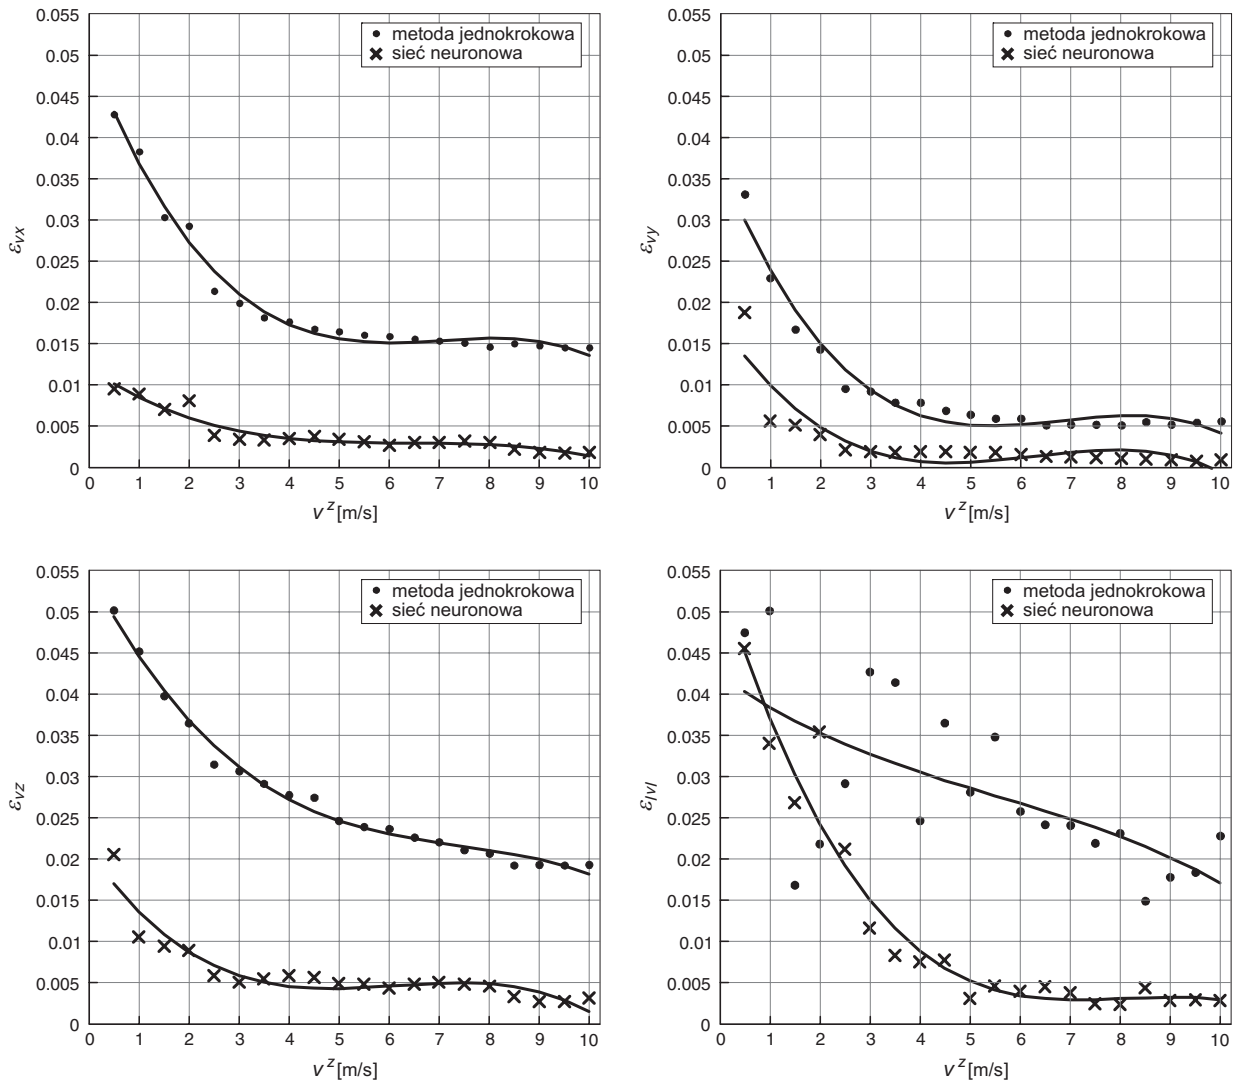
Dla metody jednokrokowej dla prędkości poniżej  $6 \text{ ms}^{-1}$  błąd średniokwadratowy modułu ma charakter bardzo przypadkowy i dla prędkości  $1.5, 2 \text{ ms}^{-1}$  jest mniejszy od błędu wyznaczonego dla sieci neuronowej.





Rys. 7. Błąd względny dla składowych oraz modułu wektora prędkości wyznaczonych za pomocą:  
a) sztucznej sieci neuronowej, b) metody jednokrokowej.

Do porównania metody jednokrokowej z siecią neuronową użyto także wskaźnika  $\lambda$  (Socha i Ligeza, 2008). Jest on oparty na iloczynie skalarnym dwóch wektorów unormowanym do kwadratu modułu zadawanej prędkości:



Rys. 8. Błąd średniokwadratowy w funkcji zadawanej prędkości dla składowych wektora prędkości oraz modułu wyznaczonych za pomocą sieci neuronowej oraz metody jednokrokowej. Linia ciągłą zaznaczono krzywą regresji

$$\Lambda = \frac{|v^o| |v^z| \cos \varphi}{|v^z|^2} \quad (6)$$

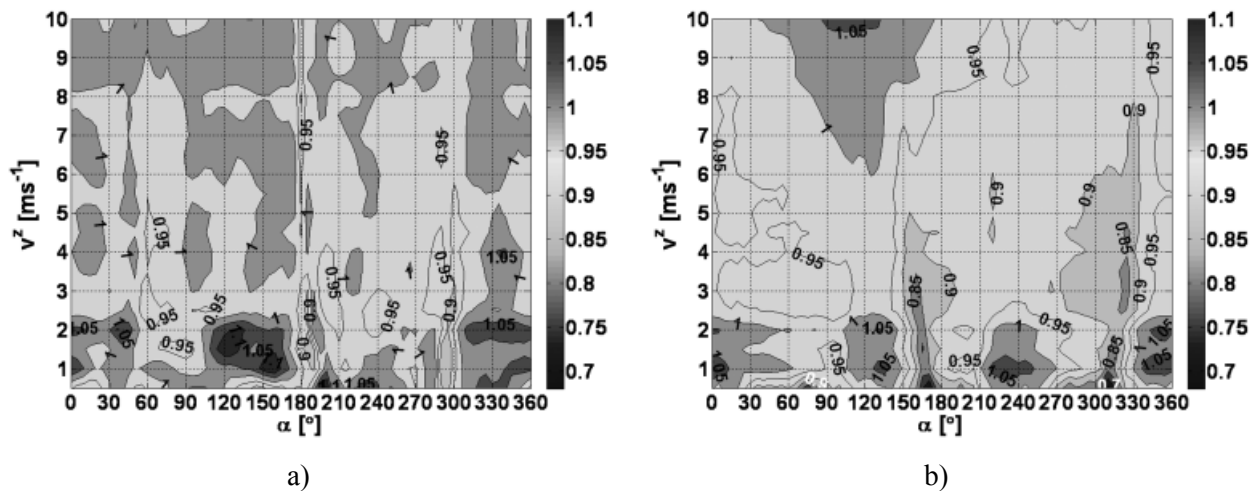
gdzie:  $\varphi$  – kąt zawarty pomiędzy zadawanym wektorem prędkości w tunelu aerodynamicznym, a wektorem wyznaczonym z pomiarów.

Wskaźnik  $\Lambda$  obliczony dla wektora prędkości wyznaczonego za pomocą sieci neuronowej i metody jednokrokowej przedstawiono na rysunku 9 w postaci mapy konturów. W przypadku, gdy wektor wyznaczony z pomiarów jest taki sam jak wektor zadawany to wskaźnik powinien wynosić 1. Dla sieci neuronowej otrzymano więcej obszarów odpowiadających wartości 1 wskaźnika  $\Lambda$ , co świadczy o lepszym dopasowaniu wyników do danych teoretycznych. Dla sieci neuronowej wartość wskaźnika różni się od jedności o  $\pm 10\%$ , natomiast w przypadku metody jednokrokowej od  $-30\%$  do  $10\%$ . Największe różnice otrzymano dla prędkości poniżej  $2 \text{ ms}^{-1}$ .

## 5. Podsumowanie

W Pracowni Metrologii Przepływów IMG PAN do wyznaczania składowych wektora prędkości z napięć pomiarowych wykorzystywano metody oparte na równaniach Kinga oraz Jorgensena, np. metodę jednokrokową. Metody te wprowadzały duże błędy do otrzymywanych wyników wynikające z zastosowanego





Rys. 9. Wskaźnik  $\Lambda$  dla a) sztucznej sieci neuronowej oraz b) metody jednokrokowej

algorytmu, a także z konstrukcji stosowanej sondy pomiarowej. W zaproponowanej w artykule metodzie wykorzystującej sztuczne sieci neuronowe miano na celu wyeliminowanie tego typu błędów. Z przeprowadzonej analizy błędów wynika, że uzyskano poprawę otrzymanych wyników. Wyznaczony wskaźnik jakości jest ponad cztery razy mniejszy niż w przypadku metody jednokrokowej. Natomiast dla wybranej struktury sieci nie udało się do końca wyeliminować błędów wynikających z budowy samej sondy trójwłókowej. W położeniach, w których następuje przysłanianie włókien otrzymano największe wartości błędów.

Dalsze prace powinny skupić się na dopracowaniu struktury sieci neuronowej oraz ulepszeniu procesu uczenia sieci, przez powiększenie zbioru uczącego i testowego.

Praca została wykonana w roku 2009 w ramach prac statutowych realizowanych w IMG PAN w Krakowie, finansowanych przez Ministerstwo Nauki i Szkolnictwa Wyższego.

## 6. Literatura

- Ciombor K., 2004. *Programowany termooanemometryczny system pomiarowy*. Mechanizacja i Automatykacja Górnictwa, tom 8: s. 5-11.
- Gawor M., 1999. *Karta szybkiego przetwornika analogowo cyfrowego z oprogramowaniem*. Metrologia i Systemy Pomiarowe. VI: s. 249-255.
- Gawor M., Socha K., 2004. *Struktura oprogramowania i możliwości metrologiczne sterowanego komputerowo wielokanałowego termooanemometrycznego systemu pomiarowego*. Prace Instytutu Mechaniki Górniczej PAN, tom 6, nr 3-4: s. 195-204.
- Kielbasa J., 1998. *Ciepne indykatory zwrotu przepływu*. W *Prace Naukowe Instytutu Techniki Ciepłej i Mechaniki Płynów Politechniki Wrocławskiej*, s. 363-370. Swieradów Zdrój.
- Kielbasa J., 2001. *Ciepły indykator zwrotu przepływu*. Mechanika, tom 20: s. 189-203.
- Ligeza P., 2003. *Sterowany komputerowo termooanemometryczny system pomiarowy pracujący w oparciu o koncepcję sterowanego układu stałotemperaturowego*. Prace Instytutu Mechaniki Górniczej PAN, tom 5, nr 2: s. 237-244.
- Ligeza P., Socha K., 2005. *Modification of an algorithm for determining the gas flow velocity components in hot-wire measurements*. Archives of Mining Sciences, tom 50, nr 3: s. 327-341.
- Ligeza P., Socha K., 2007. *Optimization of an algorithm for measurements of velocity vector components using a three-wire sensor*. Review of Scientific Instruments, tom 78.
- Poleszczyk E., 2002. *Termooanemometryczna metoda wyznaczania wektora prędkości przepływu gazu*. Rozprawy, Monografie. Prace Instytutu Mechaniki Górniczej PAN.
- Socha K., Ligeza P., 2008. *Studies of a hot-wire anemometric probe for the measurement of two-dimensional components and sense of a velocity vector*. Measurement Science and Technology, tom 19, nr 8: s. 0085402.1-0085402.11.
- Socha K., 2009. *Termooanemometryczna metoda wyznaczania modułów składowych oraz zwrotu wektora prędkości w dwuwymiarowych przepływach gazu*. Archives of Mining Science, Monografia 5, Kraków.

Tadeusiewicz R., 1993. *Sieci neuronowe*. Akademicka Oficyna Wydawnicza RM.

Tadeusiewicz R., 1998. *Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami*. Problemy Współczesnej Nauki, Informatyka. Akademicka Oficyna Wydawnicza PLJ, Warszawa.

## **Measurement of velocity vector using artificial neural network**

### **Abstract**

For measurement of flow velocity vector are used sensors with three orthogonal wires. In this work is presented analysis possibility using artificial neural network of measurement flow velocity vector. Neural network with two hidden layers was used to determined components of velocity vector with measurement signals. Structure of neural network was chosen experimentally. Results from neural network was compared with method based on King and Jorgensen equations.

**Keywords:** hot-wire anemometry, velocity vector, artificial neural network