


W wyniku eksperymentów przeprowadzonych oddzielnie z każdym pojedynczym ekspertem uzyskano jedną ocenę każdej pojedynczej sytuacji. Ponieważ jednak niektóre sytuacje statku różnie były oceniane przez poszczególnych ekspertów przyjęto następującą zasadę agregacji ocen: jeśli większość ekspertów (część $\geq 50\%$) oceniała daną sytuację jako niebezpieczna, to przyjmowano, że sytuacja ta jest niebezpieczna (grupowa ocena sytuacji). W ten sposób uzyskano tabelę z liczbowymi parametrami poszczególnych sytuacji oraz z ich ostateczną, wynikową oceną grupową, tab.1.

Δy [m]	α [°]	ω [°/s]	Ocena średnia	Ocena wynikowa {0,1}
-48.33	-3.90	11.5	0.77	1
28.78	-13.40	-12.30	0.50	1
37.47	4.80	-8.30	0.49	0
8.14	-14.40	1.60	0.51	1
-0.54	0.20	5.90	0.07	0
.....


Tab.1. Przykładowe wartości zmiennych $\Delta y, \alpha, \omega$ charakteryzujących pozycję statku oraz oceny tych sytuacji dokonane przez wieloosobową grupę ekspertów. "0"-sytuacja bezpieczna, "1"-sytuacja niebezpieczna.

Ocena średnia to stosunek liczby ekspertów oceniających daną sytuację jako niebezpieczna i całkowitej liczby ekspertów. Każda z pojedynczych sytuacji wraz z jej oceną tworzy jeden punkt w 3-wymiarowej przestrzeni zmiennych niezależnych problemu.



Rys.11. Dwa przykładowe punkty w przestrzeni zmiennych charakteryzujących pozycję statku: sytuacja bezpieczna B o małych wartościach zmiennych $\{\Delta y, \alpha, \omega\}$ oraz niebezpieczna sytuacja NB o dużych wartościach tych zmiennych.

Ogółem grupa ekspertów oceniła 269 różnych sytuacji. Tworzą one 269 punktów przedstawionych na rys.12.



Rys.12. 269 punktów reprezentujących oceniane sytuacje nawigacyjne oraz utworzone przez nie klasterzy: 2 klasterzy sytuacji niebezpiecznych (NB1 i NB2) oraz jeden klaster sytuacji bezpiecznych B.

Punkty te grupują się w 3 wyraźnych klasterach: jeden klaster sytuacji bezpiecznych B leżący wokół początku układu współrzędnych $\{0,0,0\}$, jeden klaster sytuacji niebezpiecznych NB1 leżący w strefie dużych ujemnych wartości zmiennych $\{\Delta y, \alpha, \omega\}$ oraz drugi klaster "niebezpieczny" NB2 leżący w strefie dużych dodatnich wartości tych zmiennych.

Bardzo ważne!

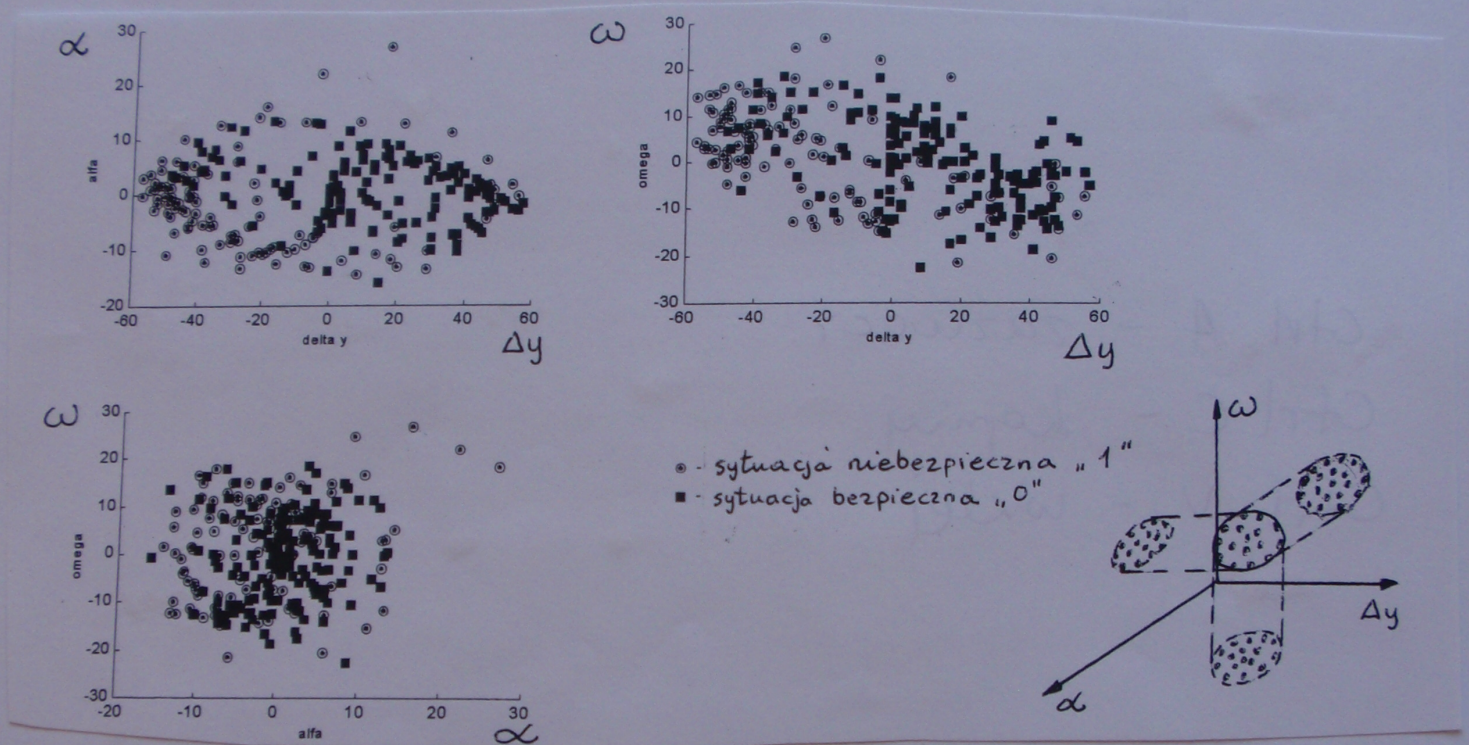
Proszę zwrócić uwagę na fakt, że próbki sytuacji NB1 i B oraz NB2 i B mieszają się ze sobą w brzegowych strefach klasterów. Są to właśnie te strefy, gdzie sytuacje są trudne do oceny i gdzie nawet cała grupa ekspertów może dokonać pomyłki i sytuację leżącą bliżej punktu $\{0, 0, 0\}$ ocenić jako niebezpieczną, a sytuację leżącą dalej od tego punktu, za bezpieczną. Zwróć też dodatkowo uwagę na tabelę 1.

Δy [m]	α [°]	ω [°/s]	Ocena średnia	Ocena wynikowa $\{0,1\}$
-48.33	-3.90	11.5	0.77	1
28.78	-13.40	-12.30	0.50	1
37.47	4.80	-8.30	0.49	0
8.14	-14.40	1.60	0.51	1
-0.54	0.20	5.90	0.07	0
.....

Tabela 1. Tabela wartości zmiennych charakteryzujących przykładowe sytuacje nawigacyjne.

W tabeli tej 3 sytuacje zaznaczone grubszą czcionką uzyskały bardzo podobną średnią ocenę (0.49),(0.50),(0.51) grupy ekspertów. Sytuacja z oceną (0.49) została zaklasyfikowana jako bezpieczna (B), a sytuacje z ocenami (0.50) i (0.51) za niebezpieczne (NB), mimo, że sytuacje te różnią się pod względem średniej oceny minimalnie: o 0.01 i o 0.02. Wystarczy, że w grupie 20 ekspertów jeden ekspert pomylił się w ocenie sytuacji a średnia ocena przekroczy

poziom 0,5, co spowoduje uznanie tej sytuacji za niebezpieczną. Jest to jedna z przyczyn mieszania się ocen sytuacji w strefach granicznych. Inną przyczyną mogą być cechy osobowościowe i doświadczenie poszczególnych ekspertów. Ekspert bardziej **ostrożny** i/lub doświadczony szybciej będzie oceniał sytuacje jako niebezpieczne. Natomiast ekspert **nieostrożny** i/lub mało doświadczony będzie miał tendencję do lekceważenia sytuacji niebezpiecznych i do uznawania ich za bezpieczne. Podobne zjawisko dotyczy problemu młodych i niedoświadczonych kierowców samochodowych. Na rys. 13 przedstawione są 2-wymiarowe rzuty 3-wymiarowych klastrów z przestrzeni zmiennych $\{\Delta y, \alpha, \omega\}$ na podprzestrzenie 2 zmiennych $\{\Delta y, \alpha\}$, $\{\Delta y, \omega\}$, $\{\alpha, \omega\}$.



Rys.13. Projektcja próbek pomiarowych 269 różnych sytuacji nawigacyjnych z pełnej 3-wymiarowej przestrzeni zmiennych $\{\Delta y, \alpha, \omega\}$ na 2-wymiarowe podprzestrzeń argumentów $\{\Delta y, \alpha\}$, $\{\Delta y, \omega\}$, $\{\alpha, \omega\}$.

Zwróć uwagę na to, że próbki białe reprezentujące sytuację B w rzutach 2D silnie mieszają się z próbkami czarnymi reprezentującymi sytuację NB - mieszanie to jest o wiele większe niż w przestrzeni pełnej 3D pokazanej na rys.12. Wynika to z faktu, że klaster NB1 leży poniżej klastra B a klaster NB2 powyżej. Klaster NB1 i NB2 **przesłaniają** więc **klaster B**, co w rzutach na podstawę i ściany boczne (podprzestrzenie 2D) daje efekt pozornego, jeszcze silniejszego mieszania się próbek sytuacyjnych. Jeżeli dysponujemy już wynikami eksperymentalnej oceny 269 sytuacji nawigacyjnych przez grupę ekspertów, to należy teraz przystąpić do opracowania matematycznych definicji (modeli) poszczególnych 3 klastrów.


Opracowanie matematycznych definicji klastrów sytuacji nawigacyjnych z użyciem 3 uogólnionych neuronów radialnych

Aby ułatwić uczenie się sieci neuronowej złożonej z 3 neuronów proces jej uczenia przeniesiono z przestrzeni 3D w 3 podprzestrzenie 2D. W każdej z tych podprzestrzeni zmiennych $\{\Delta y, \alpha\}$, $\{\Delta y, \omega\}$, $\{\alpha, \omega\}$ uczone były (strojone) 3 dwu-argumentowe neurony reprezentujące poszczególne klaster NB1, B, NB2. Po **przemnożeniu (w sensie logicznym)** 3 neuronów (ich matematycznych definicji) reprezentujących klaster NB1 w poszczególnych 3 podprzestrzeniach 2-argumentowych uzyskuje się jedną 3-argumentową, a więc pełną definicję klastra NB1. To samo dotyczy pozostałych klastrów: B oraz NB2. W radialnych sieciach neuronowych najczęściej stosowane są typowe, regularne, symetryczne radialne neurony RBF (Radial Basis Functions). Jednak rzeczywiste zgrupowania próbek reprezentujących różne klasy prawie nigdy nie są ani regularne (np. kuliste) ani symetryczne. Aby uzyskać dokładniejsze matematyczne definicje (modele) klastrów, bardziej dopasowane do rzeczywistego rozkładu próbek w przestrzeni zmiennych, korzystne jest zastosowanie uogólnionych neuronów radialnych. Matematyczna funkcja takiego neuronu w wersji 2-argumentowej podana jest przez wzór (1).

$$x_i^* = (x_i - m_i) \cos \alpha_{ij} + (x_j - m_j) \sin \alpha_{ij}, \quad x_j^* = -(x_i - m_i) \sin \alpha_{ij} + (x_j - m_j) \cos \alpha_{ij} \tag{1}$$


$$\mu(x_i^*, x_j^*) = \exp \left[- \left| \frac{x_i^*}{v_{ij} \cdot c_{i1} + (1 - v_{ij}) \cdot c_{i2}} \right|^{l_{ij1}} - \left| \frac{x_j^*}{w_{ij} \cdot c_{j1} + (1 - w_{ij}) \cdot c_{j2}} \right|^{l_{ij2}} \right]$$

Rys.14 przedstawia wizualnie powierzchnię jaką generuje taki neuron.



Rys.14. Jeden z możliwych kształtów, jaki może przyjąć uogólniona, obrotowa i niesymetryczna funkcja Gauss'a - funkcja definiująca uogólniony neuron radialny.

Wysokość tej funkcji $\mu(x_1^*, x_2^*)$ informuje nas o tym, ile charakterystycznej cechy μ danej klasy, np. klasy bezpiecznej, posiada punkt o konkretnych liczbowych wartościach x_1, x_2 , gdzie: $x_1 = \Delta y, x_2 = \alpha$. Na rys. 15 przedstawiono 2 przykładowe poziomicie reprezentujące 2 przekroje uogólnionej funkcji Gauss'a z rys.14, zrobione na różnej wysokości.




$$x_i^* = (x_i - m_i) \cos \alpha_{ij} + (x_j - m_j) \sin \alpha_{ij}, \quad x_j^* = -(x_i - m_i) \sin \alpha_{ij} + (x_j - m_j) \cos \alpha_{ij}$$

$$\mu(x_i^*, x_j^*) = \exp \left[- \frac{x_i^*}{v_{ij} \cdot c_{i1} + (1 - v_{ij}) \cdot c_{i2}} \right] - \frac{x_j^*}{w_{ij} \cdot c_{j1} + (1 - w_{ij}) \cdot c_{j2}} \right]$$


Rys.15. Dwa przekroje (poziomicie) 2-argumentowej funkcji Gauss'a $\mu(x_1, x_2)$ opisanej wzorem(1).

Każda z tych dwóch poziomic jest krzywa stałej ilości cechy danej klasy - poziomicą wewnętrzną reprezentuje wyższą ilość cechy klasy (np. bezpiecznej) a poziomicą zewnętrzną reprezentuje niższą ilość cechy. Najwyższą ilość cechy (równą 1) posiada punkt o współrzędnych $\{m_1, m_2\}$ nazywany **środkiem** neuronu, środkiem klastra definiowanego przez ten neuron, lub też środkiem funkcji Gauss'a. Zmiana wartości $\{m_1, m_2\}$ powoduje przesuwanie się środka neuronu wzdłuż osi zmiennych x_1, x_2 . Zmieniając wartości $\{m_1, m_2\}$ sieć neuronowa może w trakcie procesu jej uczenia przesunąć neuron z niedoskonałej pozycji startowej (losowo określonej na początku procesu uczenia sieci) w rejon, w którym znajdują się próbki tej klasy, która dany neuron ma reprezentować (definiować), rys.16.



Rys. 16. Ilustracja znaczenia zmian współrzędnych pozycji środka neuronu $\{m_1, m_2\}$ dla procesu uczenia (strojenia parametrów) neuronu.

Kąt α_c informujący o kątowym ustawieniu uogólnionego neuronu Gauss'a (nie należy mylić z kątem α odchylenia kursu statku) umożliwia w procesie uczenia neuronu takie jego ustawienie, które pozwoli neuronowi jak najdokładniej dopasować się do próbek uczących, rys.17.

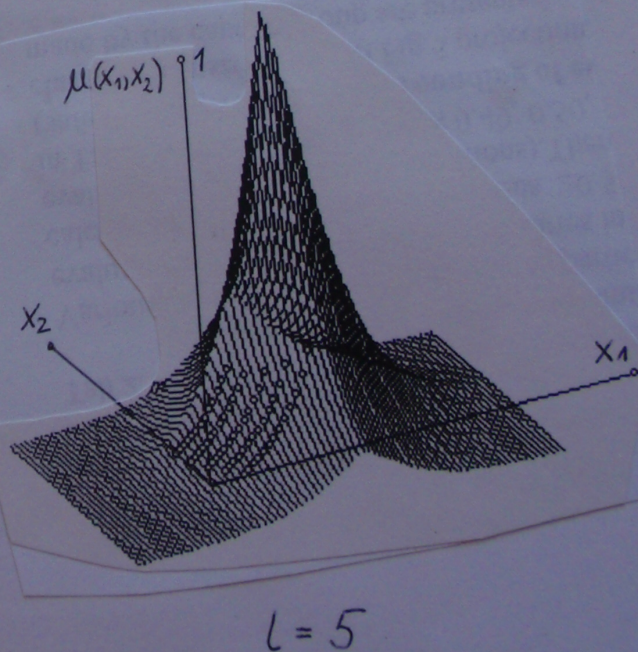
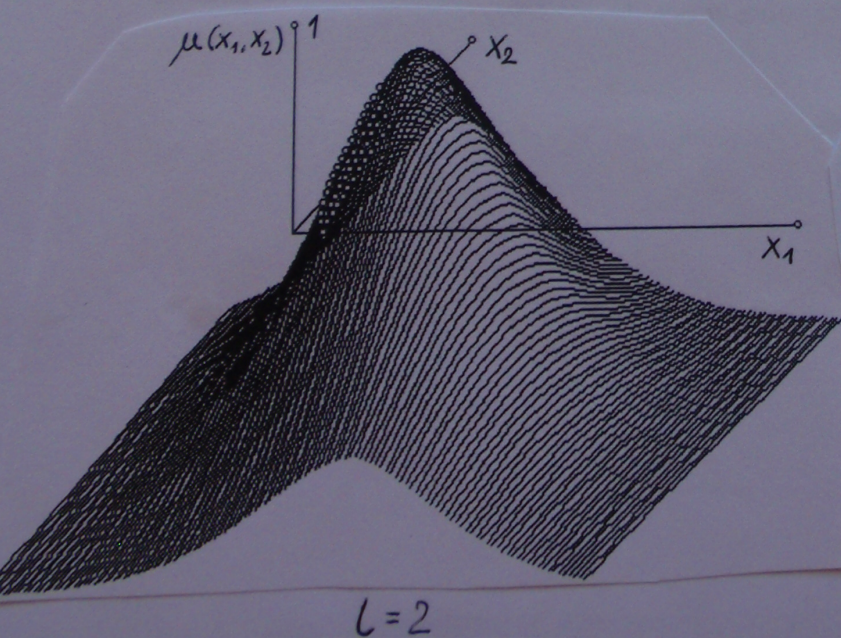


Rys.17. Ilustracja znaczenia kąta α_c uogólnionego neuronu Gauss'a dla procesu uczenia neuronu.

We wzorze (1) występuje wykładnik potęgi "l". Zmiana wartości tego wykładnika umożliwia


$$\mu(x_i^*, x_j^*) = \exp \left[- \left| \frac{x_i^*}{v_{ij} \cdot c_{i1} + (1 - v_{ij}) \cdot c_{i2}} \right|^{l_{ij1}} - \left| \frac{x_j^*}{w_{ij} \cdot c_{j1} + (1 - w_{ij}) \cdot c_{j2}} \right|^{l_{ij2}} \right] \quad (1)$$

dopasowanie nachylenia powierzchni neuronu do stopnia zagęszczenia (liczby próbek) wokół środka neuronu, rys.18. Możliwości takiej nie ma zwykły neuron radialny (Gauss'a), którego potęga jest zawsze równa 2.



Rys.18. Ilustracja wpływu zmiany współczynnika potęgowego "l" w uogólnionym neuronie radialnym.

Parametry c_{ij} w uogólnionym neuronie Gauss'a oznaczają z kolei różne jego szerokości w kierunku dodatnim bądź ujemnym poszczególnych zmiennych x_1, x_2 . Zwykły neuron Gauss'a posiada identyczną szerokość we wszystkich kierunkach. Jest więc okrągły (kulisty).

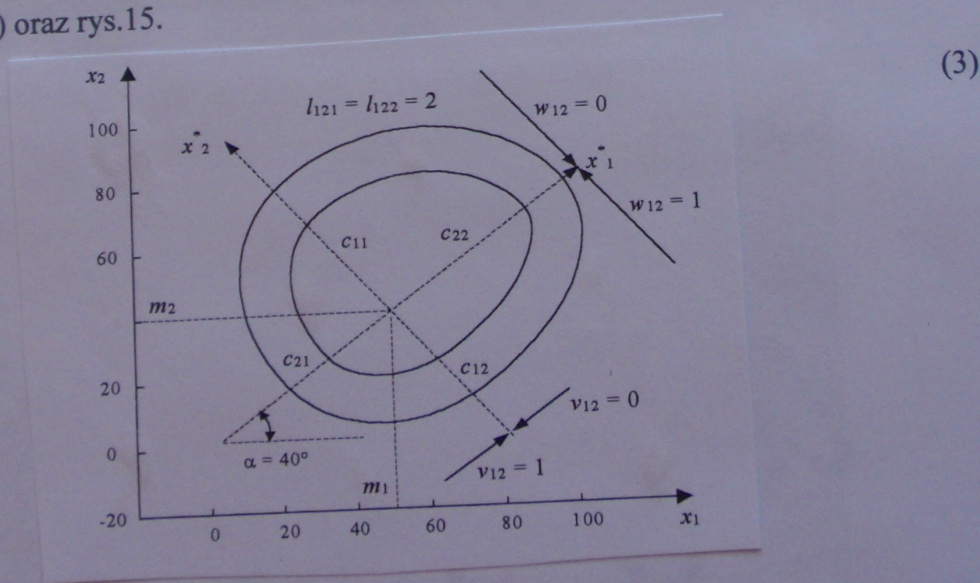


Rys.19. Ilustracja wpływu zmian parametrów c_{ij} uogólnionego neuronu Gauss'a na jego szerokości w różnych kierunkach x_i .

Ponieważ zwykły neuron Gauss'a nie jest w stanie dokładnie pokryć żadnego nieregularnego zgrupowania próbek pomiarowych to mniej dokładnie definiuje on klasę niż neuron uogólniony. Jeżeli, w przypadku neuronów zwykłych, chcielibyśmy zwiększyć dokładność definiowania klasy, to trzeba użyć kilku neuronów. Inaczej mówiąc: jeden neuron uogólniony może zastąpić kilka neuronów zwykłych. Zwykły 2-argumentowy neuron Gauss'a można opisać jednym wzorem (2).

$$\mu(x_i^*, x_j^*) = \exp\left[-(x_i^* - m_1)^2/c - (x_j^* - m_2)^2/c\right] \quad (2)$$


W przypadku uogólnionego neuronu Gauss'a konieczne są 4 wzory - po jednym dla każdej ćwiartki neuronu. Do włączania odpowiednich ćwiartek służą współczynniki v_{ij} , którym nadaje się wartości 0 lub 1 zależnie od tego w której ćwiartce neuronu leży aktualna próbka ucząca, wzór (3) oraz rys.15.



Rys.15. Dwa przekroje (poziomice) 2-argumentowej funkcji Gauss'a opisaney wzorem (3)

W procesie uczenia uogólnionego neuronu Gauss'a nie są strojone parametry jednocześnie wszystkich ćwiartek neuronu, lecz tylko parametry tej ćwiartki w której leży próbka aktualnie używana w danym kroku uczenia.

Pełny 3-argumentowy neuron $(\Delta y, \alpha, \omega)$ reprezentujący jedną z 3 możliwych sytuacji statku, NB1 lub B lub NB2, może być złożony z 3 dwuargumentowych neuronów definiujących daną klasę sytuacji w podprzestrzeniach argumentów $\{\Delta y, \alpha\}$, $\{\Delta y, \omega\}$, $\{\alpha, \omega\}$. Złożenia neuronów dokonuje się z użyciem operatora PRODUCT (iloczyn logiczny), przez pomnożenie poszczególnych modeli 2-argumentowych, rys.21.



Rys.21. Ilustracja procesu składania 2-argumentowych, cząstkowych modeli w jeden 3-argumentowy model definiujący klasę sytuacyjną statku.

Oczywiście, zamiast składać jeden 3-argumentowy neuron z trzech 2-argumentowych można by od razu użyć i nastroić jeden neuron 3-argumentowy. W niniejszym badaniu użyto jednak 3 neuronów 2-argumentowych ze względu na ułatwienie i przyspieszenie procesu uczenia. Kosztem takiego rozwiązania jest prawdopodobnie pewne obniżenie dokładności definiowania klas.

Na rys.22, 23, 24 przedstawiono wynik uczenia 2-argumentowych neuronów reprezentujących poszczególne klasy sytuacyjne NB1, B, NB2 w trzech podprzestrzeniach $\{\Delta y, \alpha\}$, $\{\Delta y, \omega\}$, $\{\alpha, \omega\}$.

