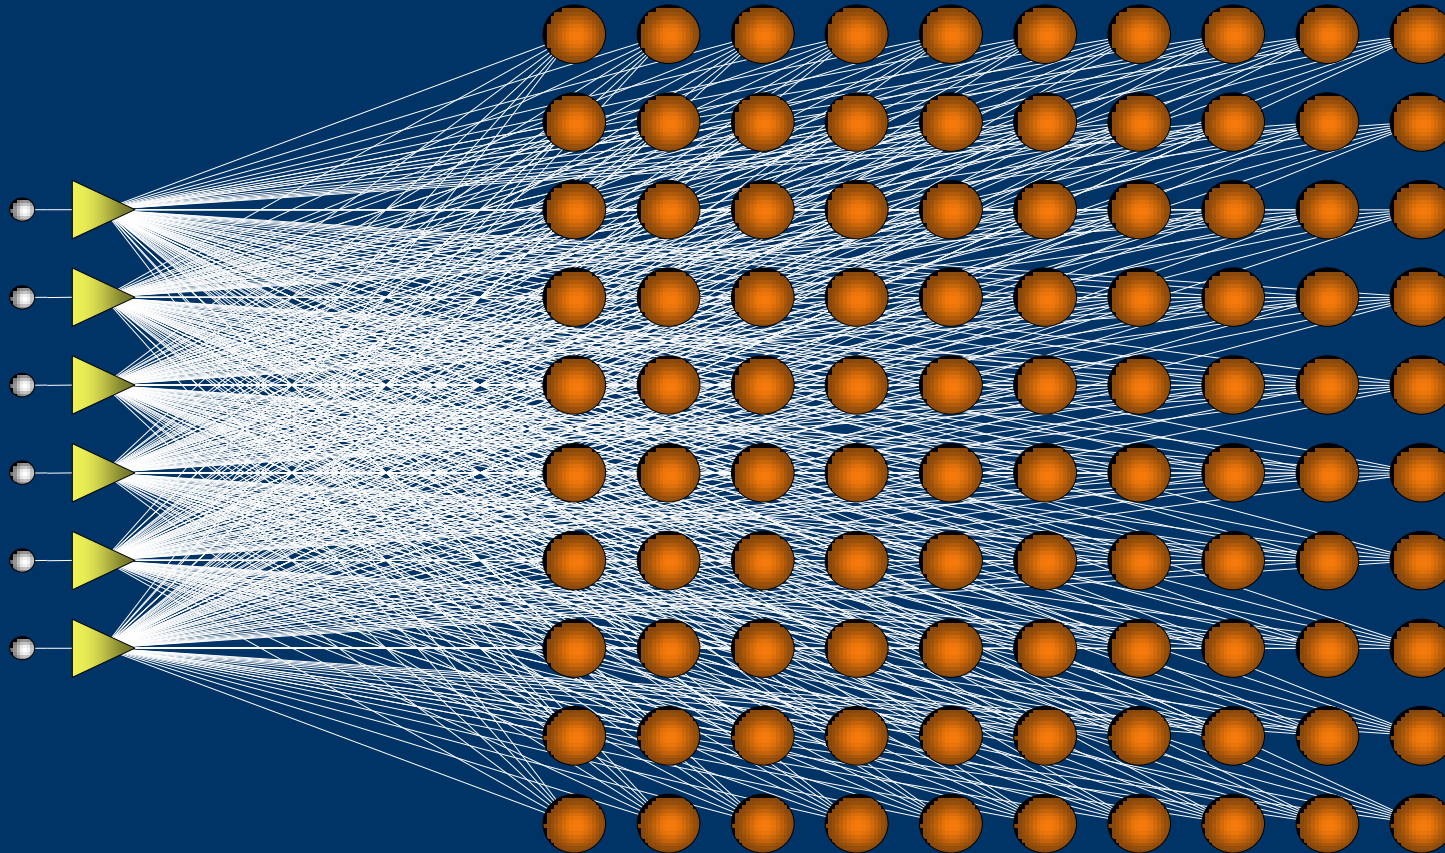


SIECI KOHONENA

UCZENIE BEZ NAUCZYCIELA



JOANNA GRABSKA-CHRZĄSTOWSKA

Wykłady w dużej mierze przygotowane w oparciu o materiały i pomysły
PROF. RYSZARDA TADEUSIEWICZA

SAMOUCZENIE SIECI

metoda Hebba

W mózgu wzmocnieniu podlegają te drogi przekazywania sygnałów, które stanowią połączenia ośrodków ulegających równoczesnemu pobudzeniu lub hamowaniu.

Dla sygnału $X = \langle x_1^{(j)}, x_2^{(j)}, \dots, x_n^{(j)} \rangle$

dla neuronu o numerze - k

sygnał wyjściowy - $y_k^{(j)}$

wagi na i -tym wejściu:

$$w_{ki}^{(j+1)} = w_{ki}^{(j)} + \eta y_k^{(j)} x_i^{(j)}$$

REGUŁA WIDROW-HOFFA (DELTA)

$$W' = W + \eta \delta X$$

$$\eta \geq 0$$

$$\delta = z - y$$

$$\delta \geq 0$$

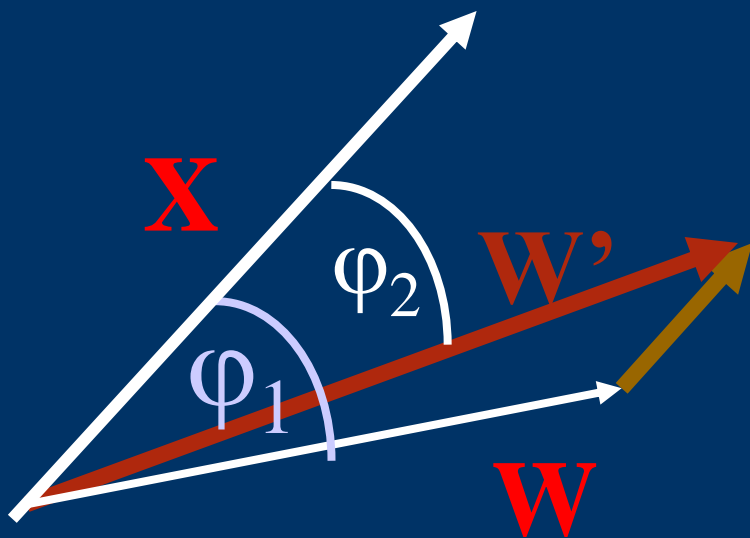


$$z - y \geq 0$$



$$z > y$$

czyli odpowiedź sieci jest **ZAMALĄ**



$$\varphi_2 < \varphi_1$$

$$\cos \varphi_2 > \cos \varphi_1$$

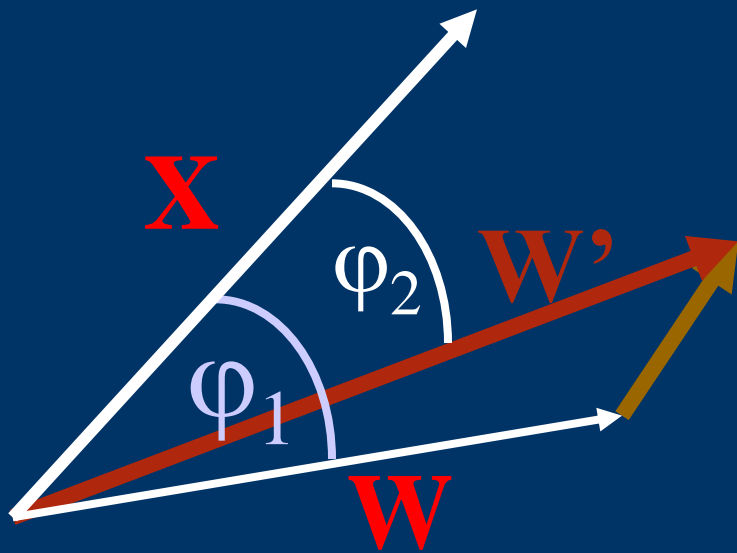
$$y_2 > y_1$$

REGUŁA HEBBA

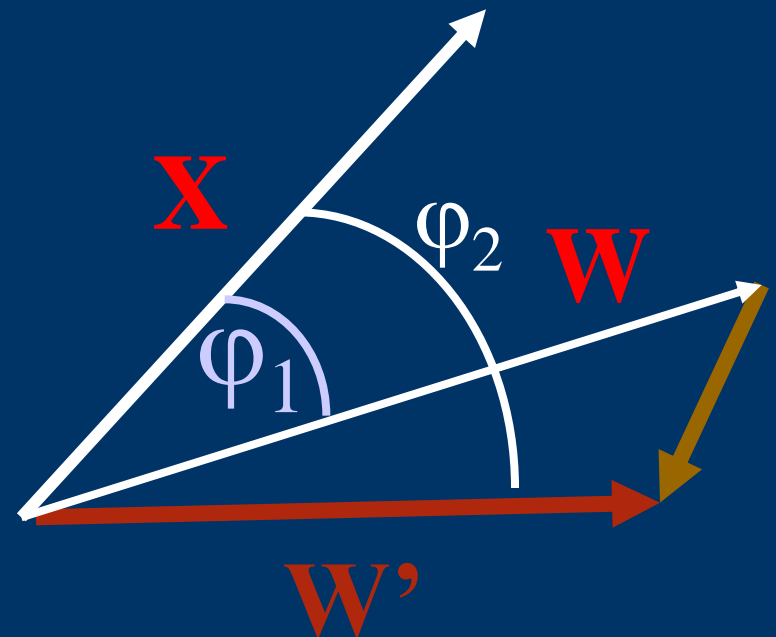
$$W' = W + \eta y X$$

$$\eta \geq 0$$

$$y > 0$$



$$y < 0$$




Samouczenie sieci metodą Hebba (2)

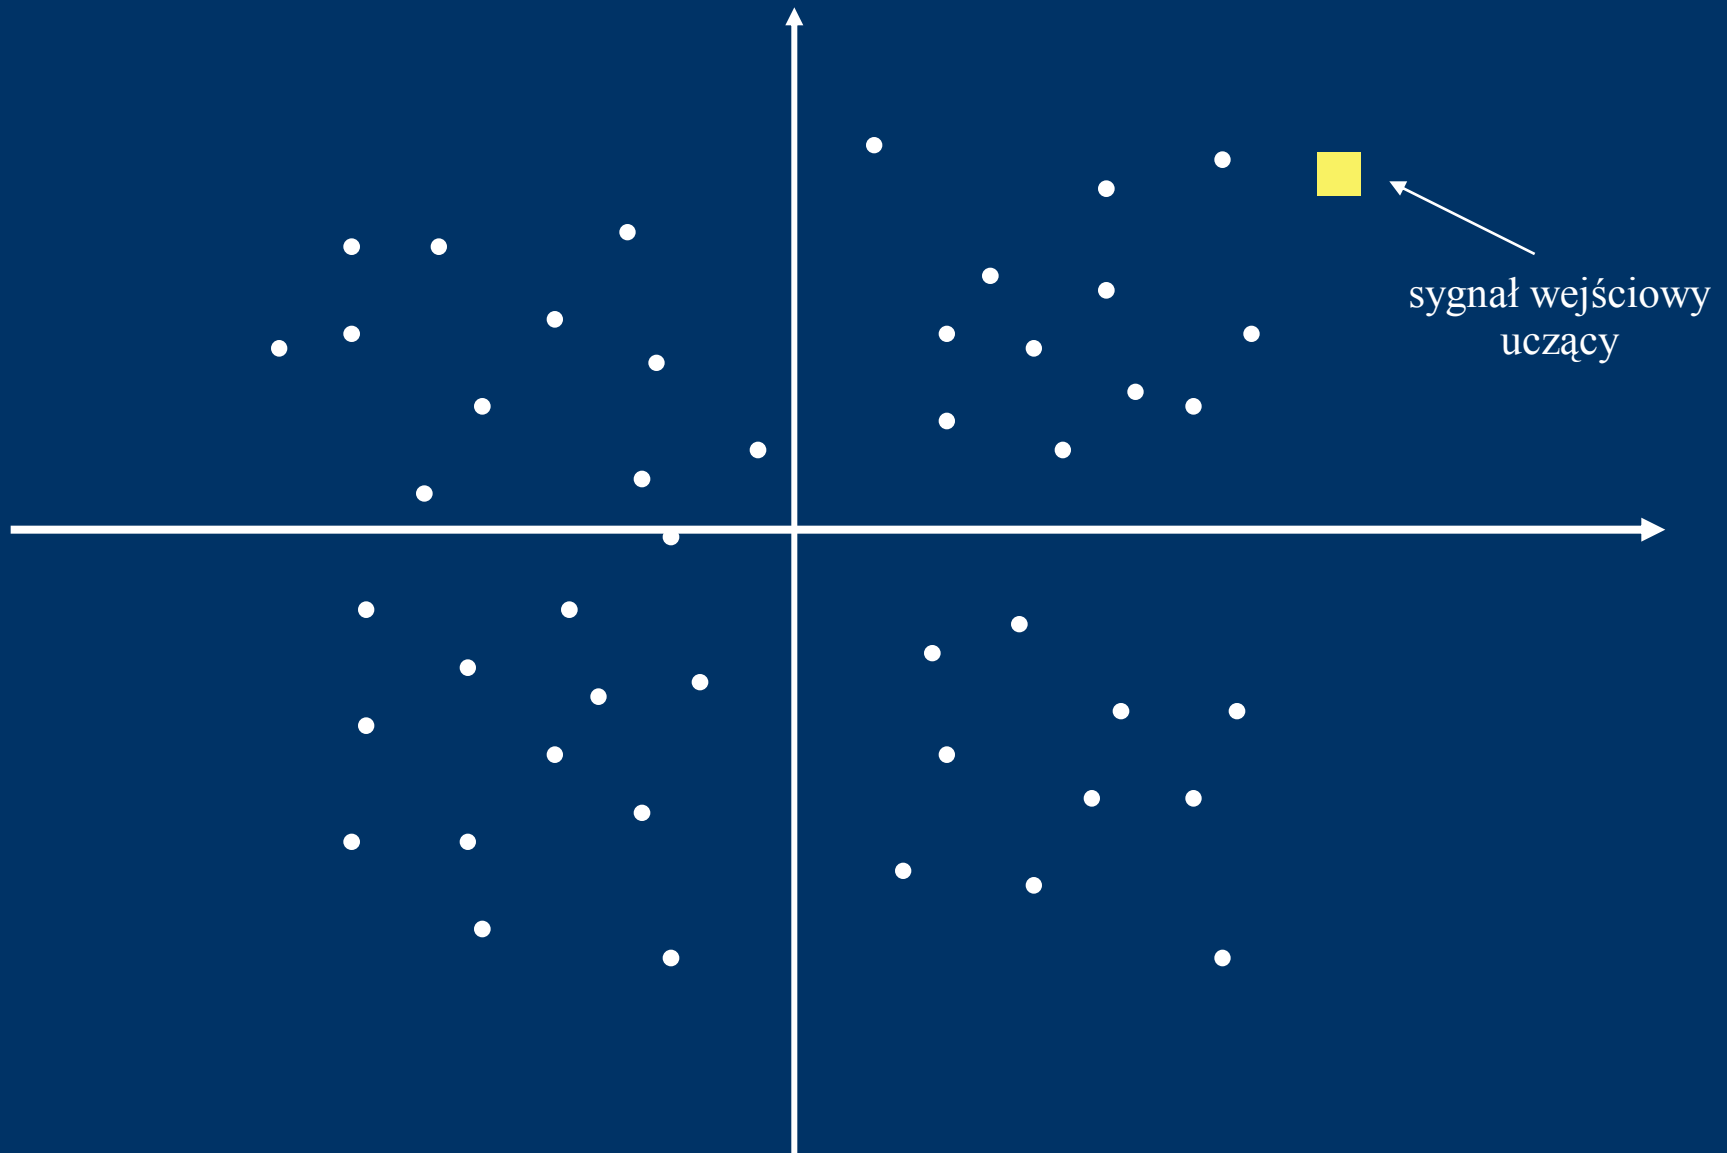
Wady samouczenia metodą Hebba:

- Stosunkowo niska efektywność uczenia
- Przemnożony wpływ początkowych wartości wag
- Możliwość pomijania niektórych klas w nauczonej sieci
- Powstawanie redundantnych nadprezentacji klas

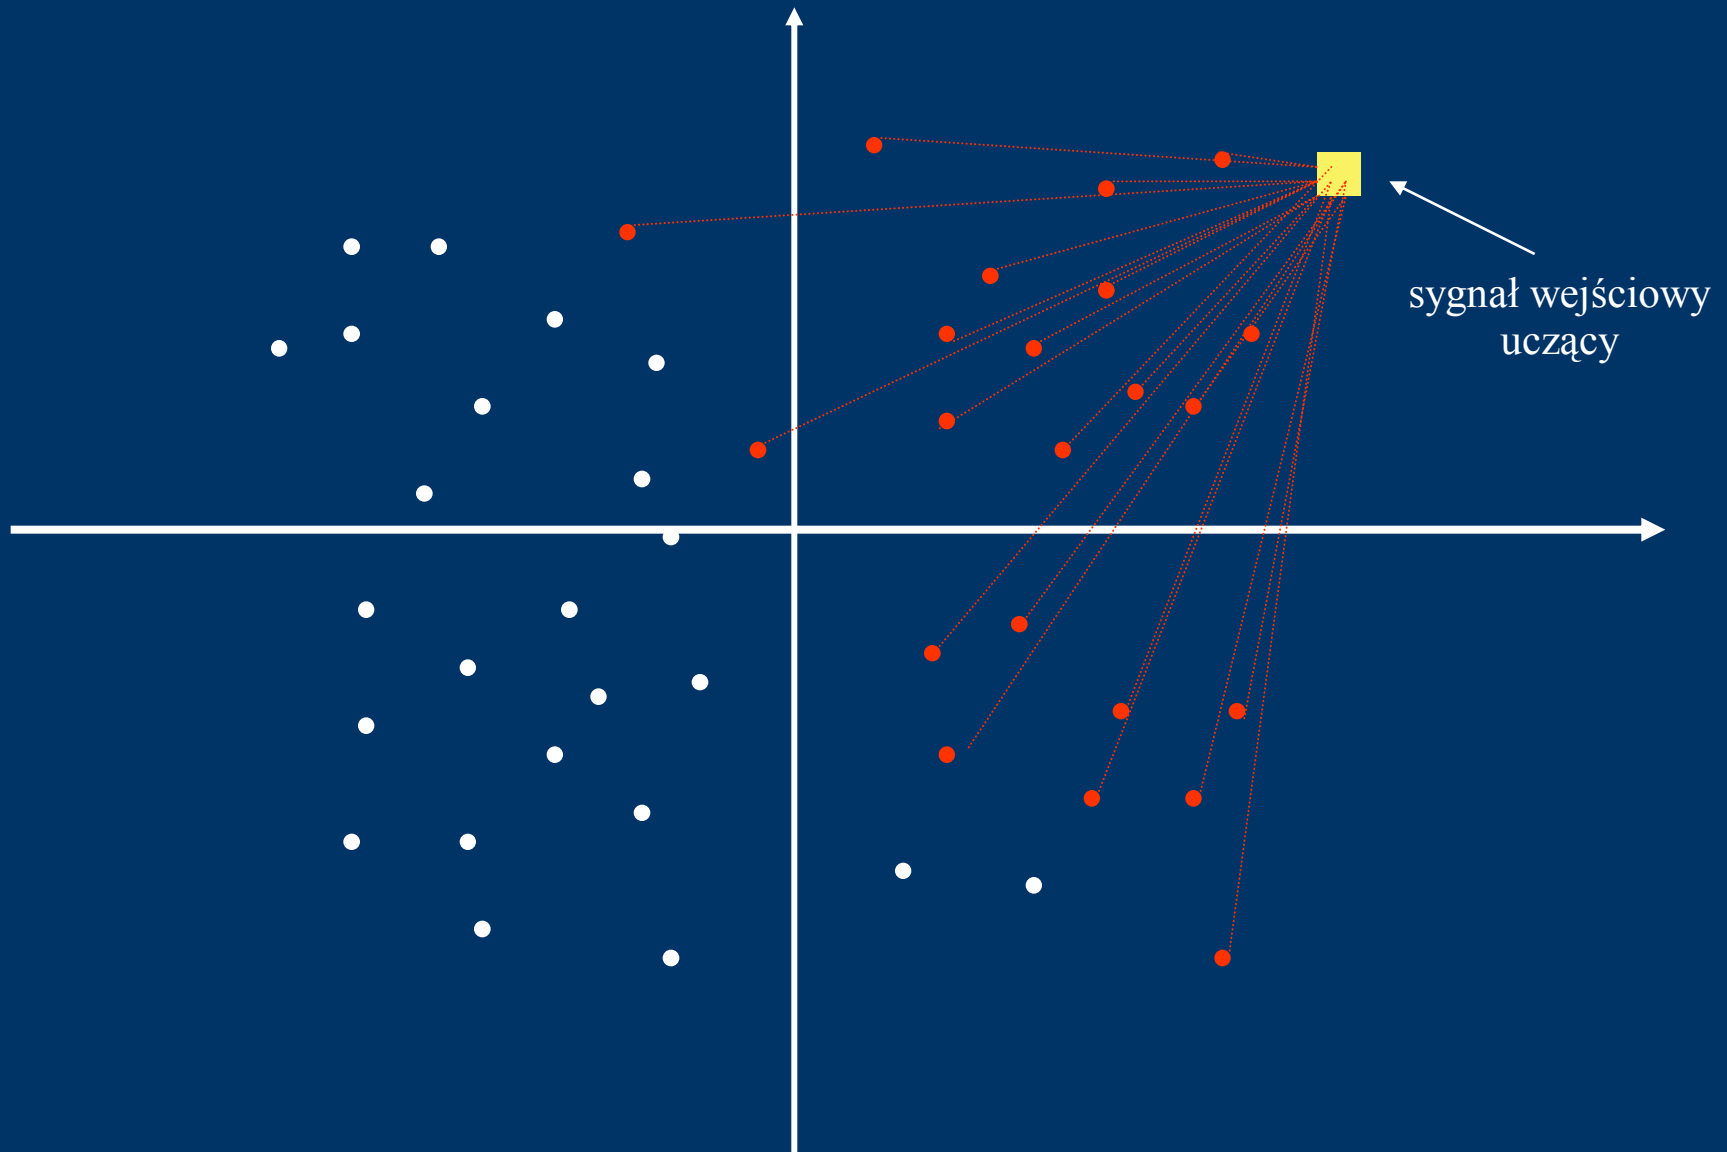
POCZĄTKOWE POŁOŻENIE PUNKTÓW REPREZENTUJĄCYCH NEURONY




PROCES SAMOUCZENIA



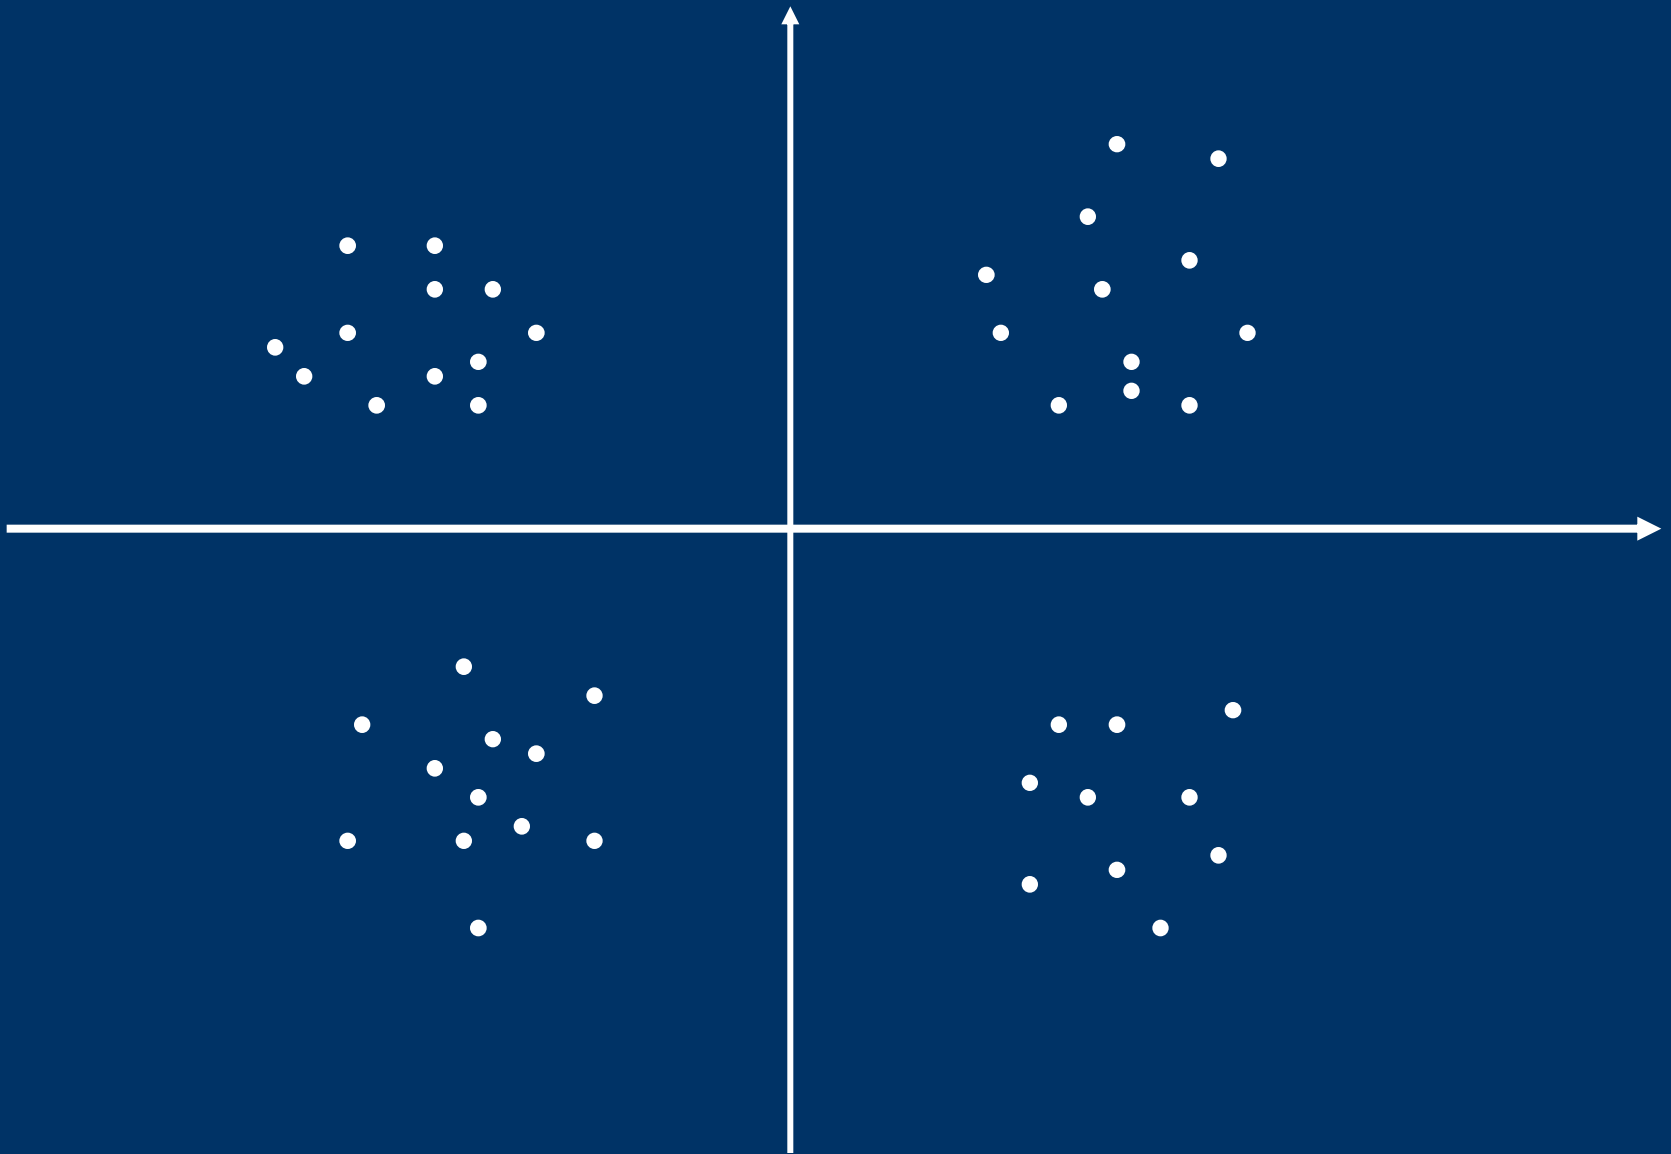
PROCES SAMOUCZENIA

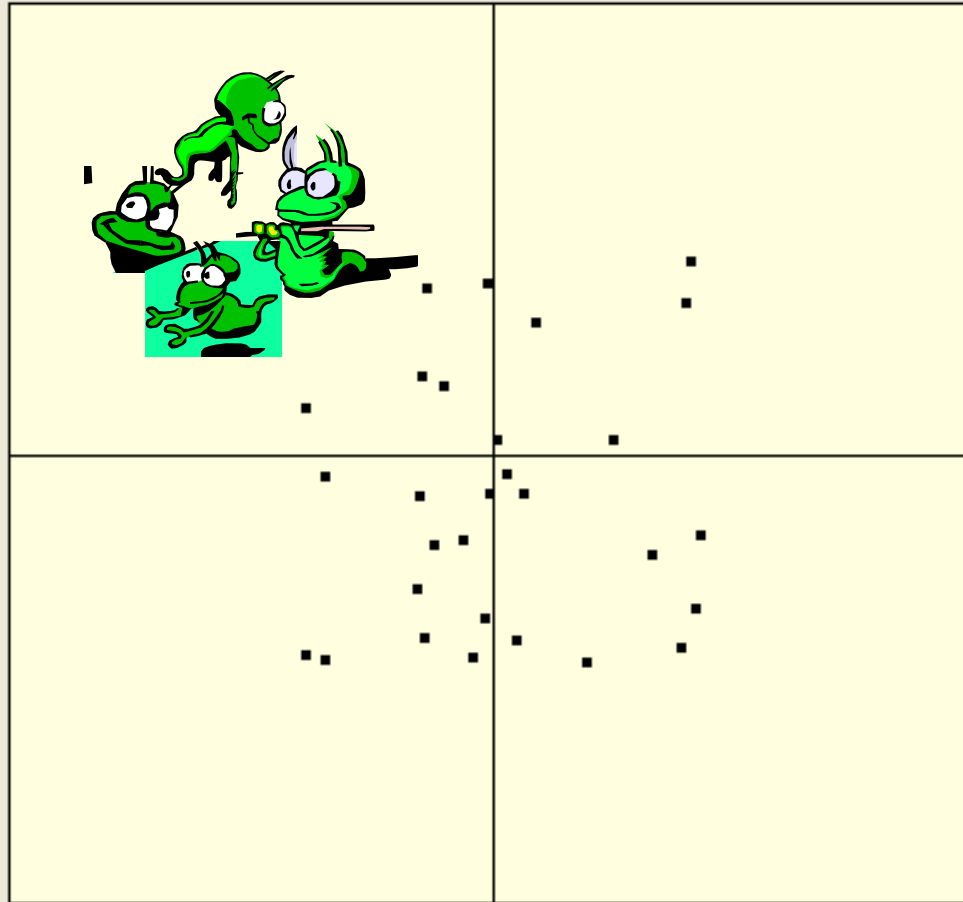


PROCES SAMOUCZENIA



Marsjanie, Marsjanki, Marsjaniątka i Marsjamory





Reset




Click a quarter for learning object

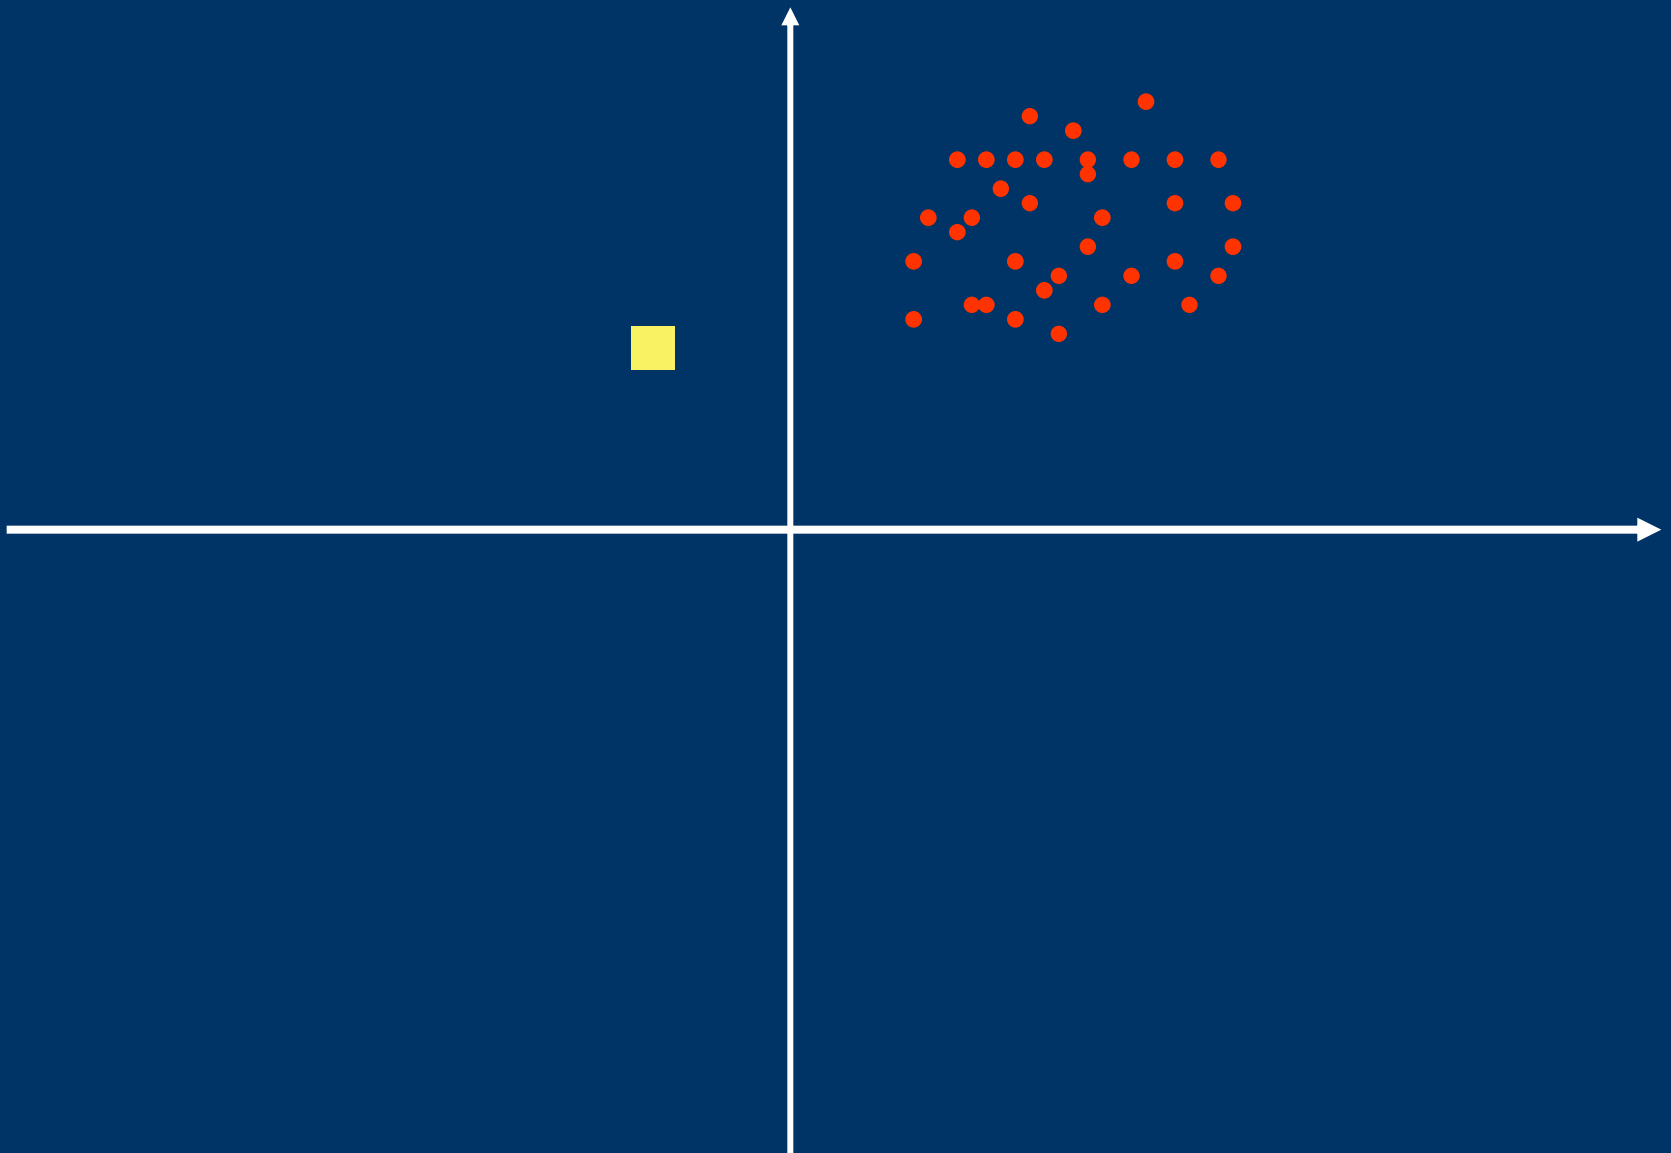
< Back

Next >


ZASADA OWCZEGO PĘDU




ZASADA OWCZEGO PĘDU




ZASADA OWCZEGO PĘDU




BARDZO DUŻY WSPÓŁCZYNNIK UCZENIA



BARDZO DUŻY WSPÓŁCZYNNIK UCZENIA




MAŁY WSPÓŁCZYNNIK UCZENIA




MAŁY WSPÓŁCZYNNIK UCZENIA

stan po pewnym czasie nauki




DŁUGOTRWALY PROCES UCZENIA

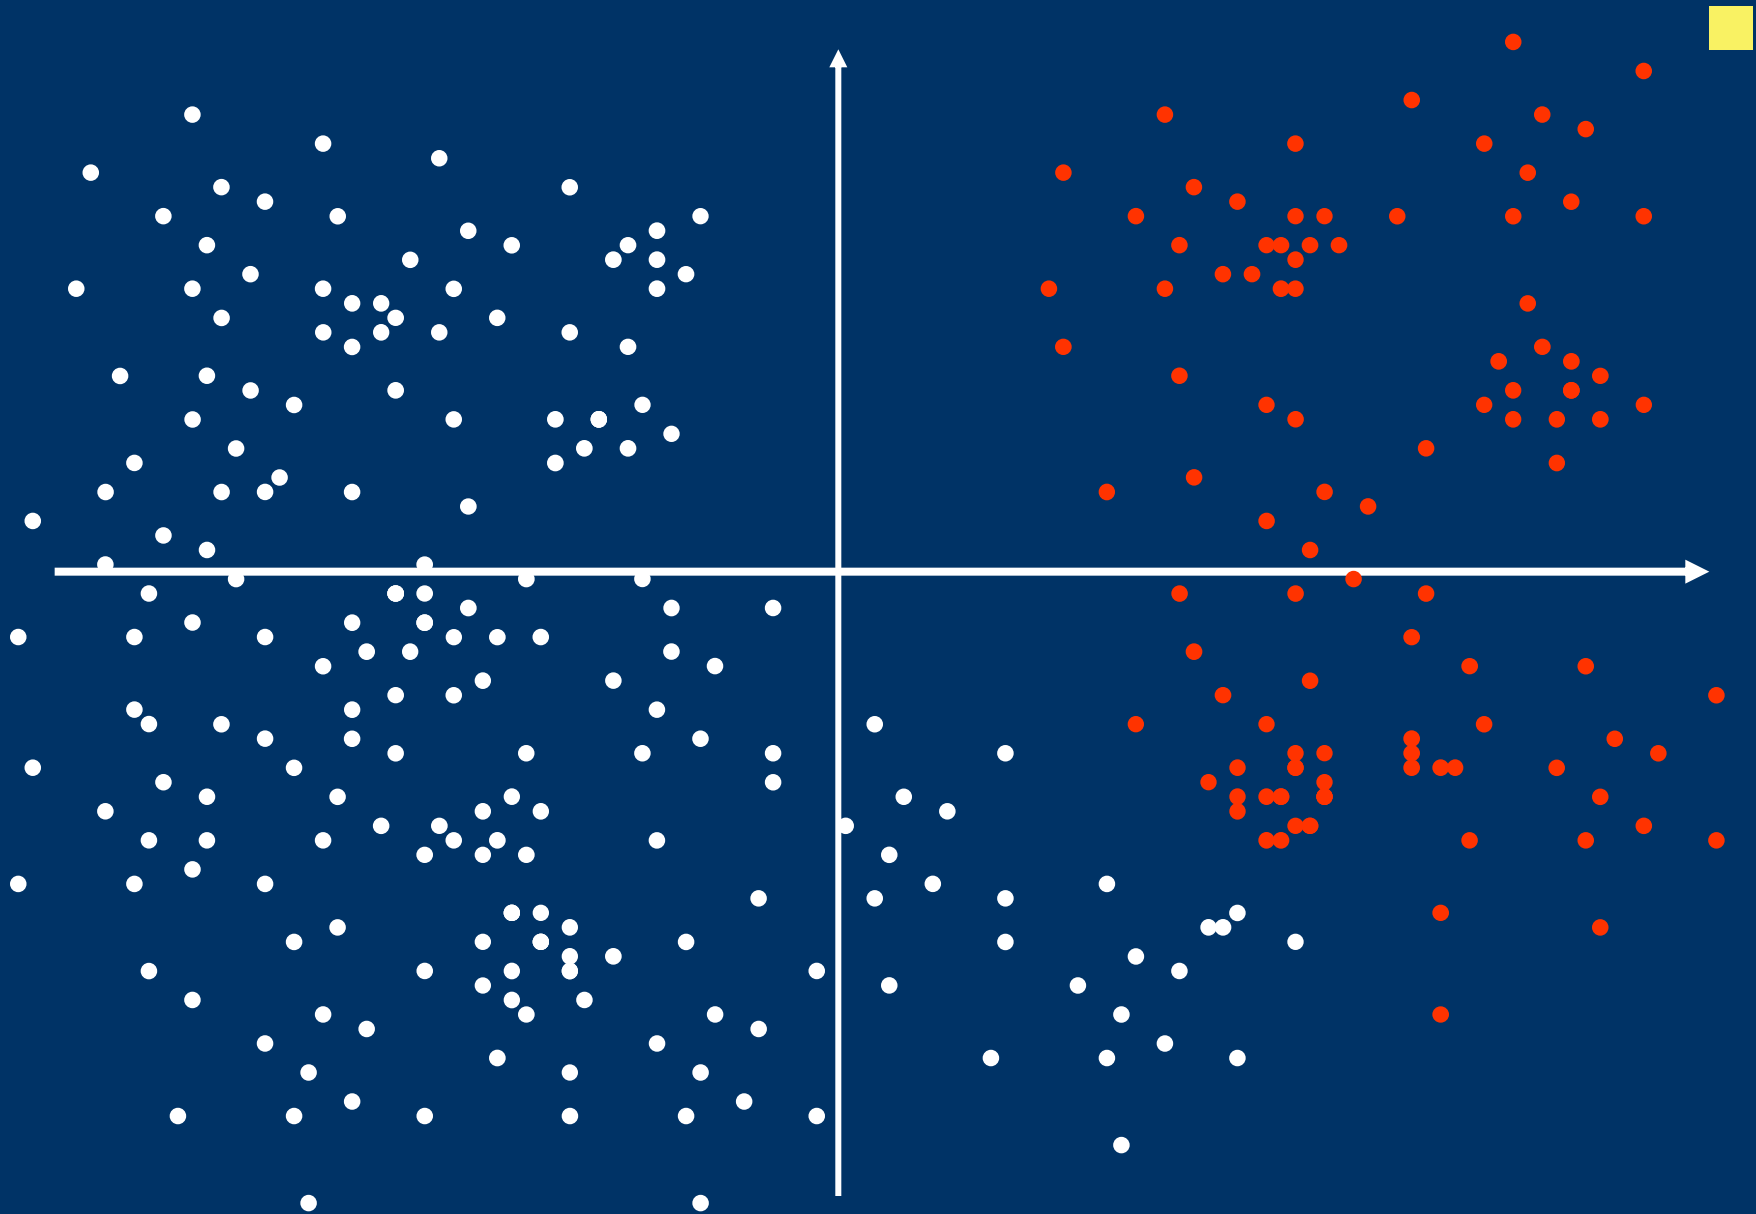
utrata zdolności do akceptowania nowości




BARDZO DUŻA LICZBA NEURONÓW



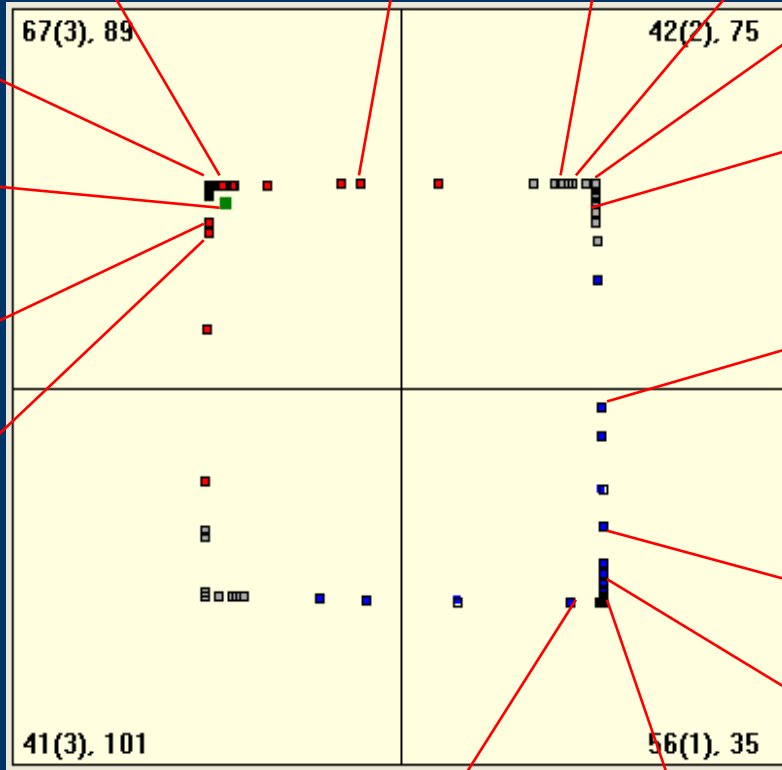





BARDZO DUŻA LICZBA NEURONÓW




BARDZO DUŻA LICZBA NEURONÓW

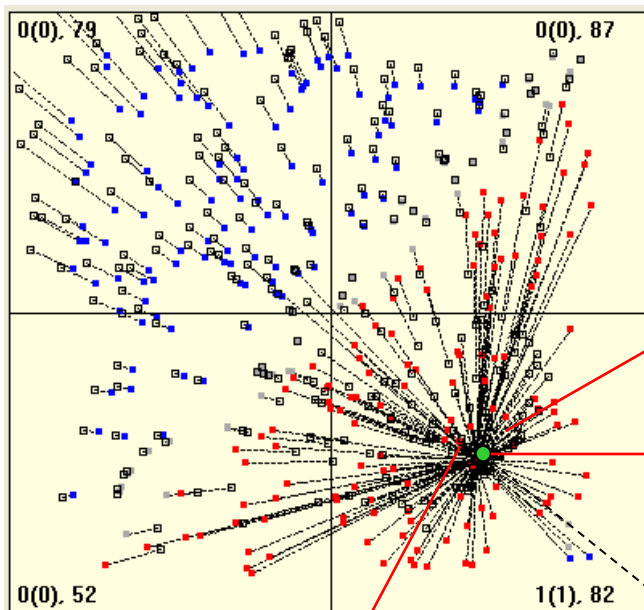


*FANTAZJE W
SIECIACH
NEURONOWYCH*



GIGANTOMANIA





Neuron pamiętający
wygląd lwa




Rzeczywisty
obraz lwa
pokazany jako
przykład uczący




Inny neuron
pamiętający lwa


Wyobrażenie „*superlwa*”
przyjęte przez jeden
z neuronów



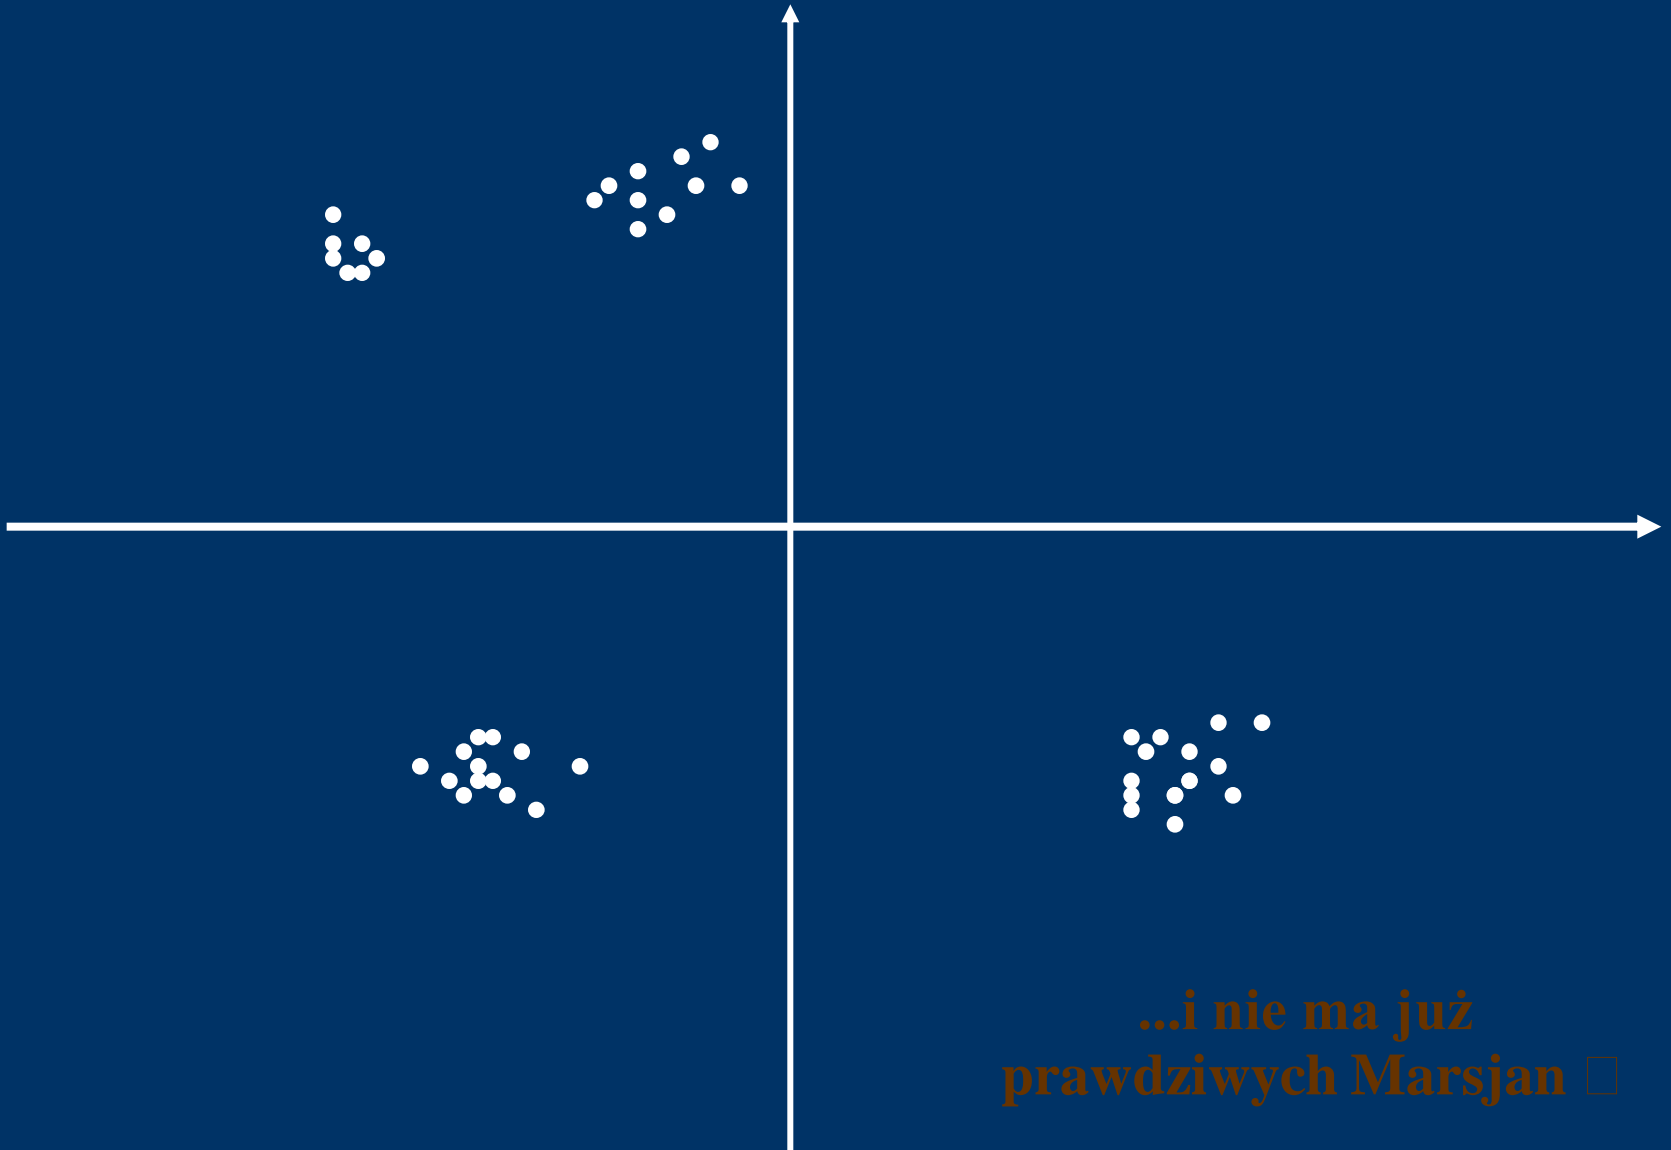
RABUNEK ...
i klasa popada w zapomnienie



RABUNEK ...
i klasa popada w zapomnienie



RABUNEK ...
i klasa popada w zapomnienie



**...i nie ma już
prawdziwych Marsjan ☐**

WARIANTY METOD SAMOUCZENIA

METODA PRZYROSTOWEGO SAMOUCZENIA (differential hebbian learning)

$$w_{ki}^{(j+1)} = w_{ki}^j + \eta \left[(x_i^j - x_i^{j-1})(y_k^j - y_k^{j-1}) \right]$$


WARIANTY METOD SAMOUCZENIA

METODA “GWIAZDY WEJŚĆ” (**instar learning**).
Jest najczęściej wykorzystywaną formułą uczenia nienadzorowanego w analizie skupień.

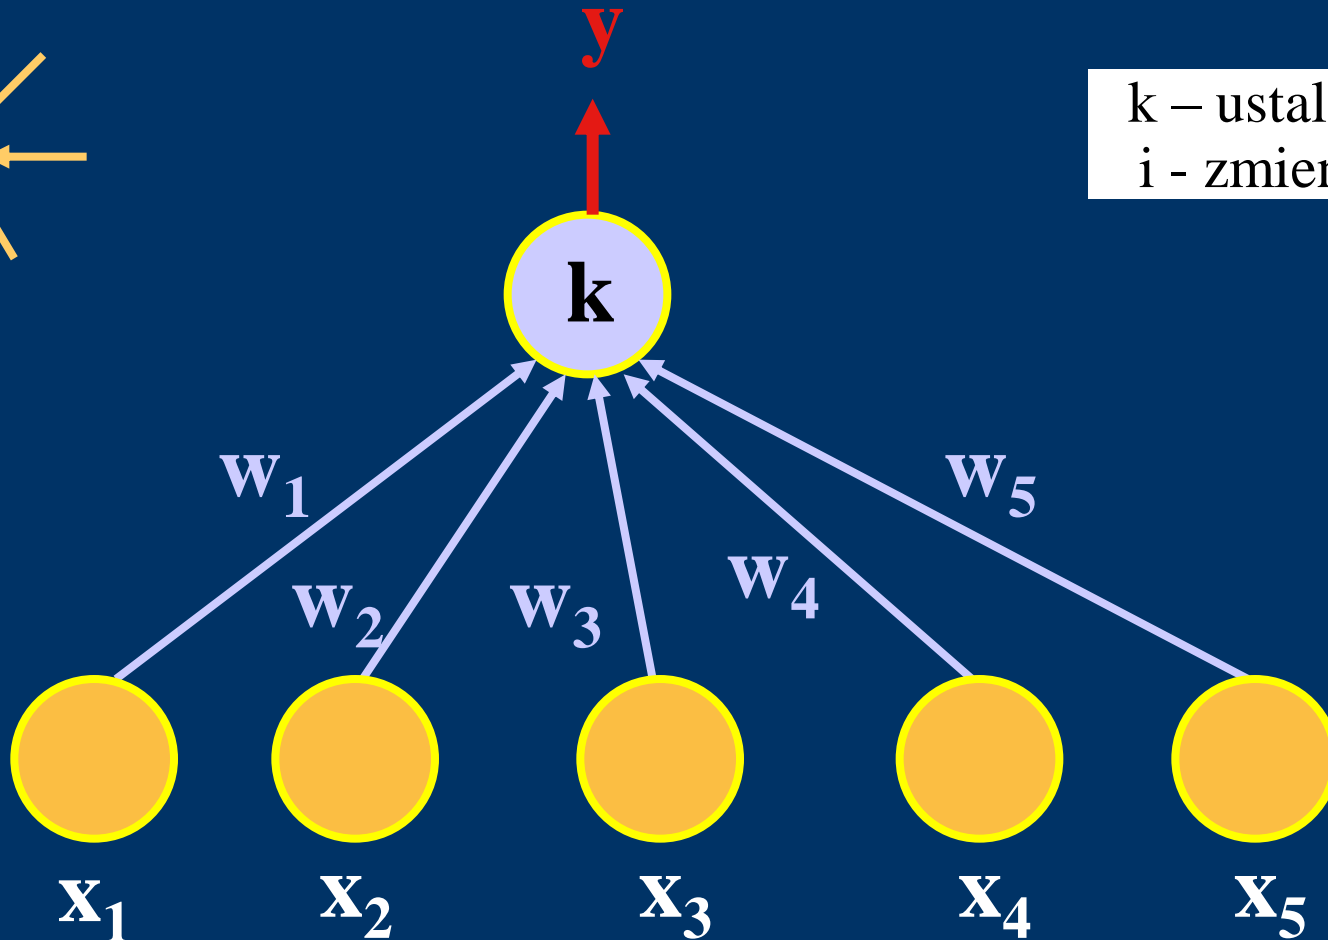
$$w_{ki}^{(j+1)} = w_{ki}^j + \eta^j (x_i^j - w_{ki}^j) \quad \eta^{(j)} = 0.1 - \lambda$$

METODA INSTAR LEARNING GWIAZDA WEJŚĆ

$$w_{ki}^{(j+1)} = w_{ki}^{(j)} + \eta [x_i^{(j)} - w_{ki}^{(j)}]$$

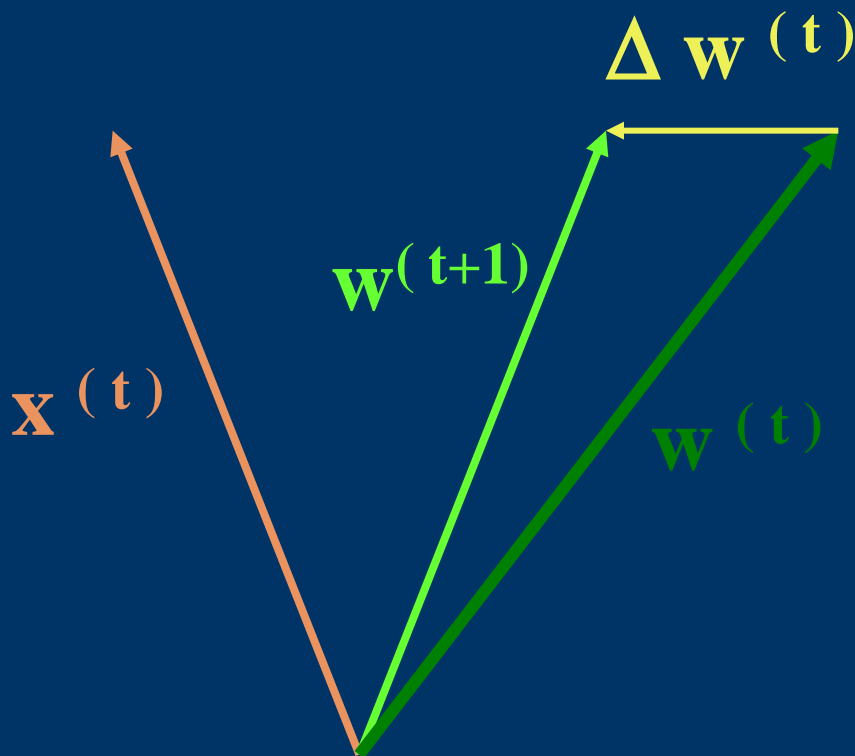


k – ustalone
i – zmienne



METODA INSTAR LEARNING

$$\mathbf{w}_{ki}^{(j+1)} = \mathbf{w}_{ki}^{(j)} + \eta [\mathbf{x}_i^{(j)} - \mathbf{w}_{ki}^{(j)}]$$




$\mathbf{x}(t)$ – wektor wejściowy
 $\mathbf{w}(t)$ – wektor wag
przed korektą
 $\Delta \mathbf{w}(t)$ – wektor poprawki
 $\mathbf{w}(t+1)$ – wektor wag
po korekcie.

Miarą podobieństwa wektora wejściowego i wektora wag jest **COSINUS KĄTA** unormowanych wektorów.


METODA OUTSTAR LEARNING “GWIAZDY WYJŚĆ”

$$w_{ki}^{(j+1)} = w_{ki}^{(j)} + \eta^{(j)} [y_k^{(j)} - w_{ki}^{(j)}]$$
$$\eta^{(j)} = 0,1 - \lambda * j$$

i – ustalone
k - zmienne



Teuvo Kohonen...



... i jego
historyczne dzieło



SAMOUCZENIE SIECI METODĄ KOHONENA

Po pojawieniu się w chwili j znormalizowanego sygnału

$$\mathbf{X} = \langle \mathbf{x}_1^{(j)}, \mathbf{x}_2^{(j)}, \dots, \mathbf{x}_n^{(j)} \rangle$$

sygnały wyjściowe wszystkich neuronów są porównywane i wybierany jest

zwycięzca tzn. neuron o numerze \mathbf{k} , którego sygnał wyjściowy $\mathbf{y}_k^{(j)}$ będzie mieć

największą wartość

to wówczas współczynnik wagi na \mathbf{i} -tym wejściu zwycięskiego neuronu zmienia się:

$$\mathbf{w}_{ki}^{(j+1)} = \mathbf{w}_{ki}^{(j)} + \eta (\mathbf{x}_i^{(j)} - \mathbf{w}_{ki}^{(j)})$$

Uczenie może być rozciągnięte na inne neurony w ramach tzw. sąsiedztwa :

$$\mathbf{w}_{mi}^{(j+1)} = \mathbf{w}_{mi}^{(j)} + \eta \mathbf{h}(\mathbf{m}, \mathbf{k}) (\mathbf{x}_i^{(j)} - \mathbf{w}_{mi}^{(j)})$$

gdzie funkcje sąsiedztwa $\mathbf{h}(\mathbf{m}, \mathbf{k})$ określona jako malejąca funkcja odległość ρ

między neuronem \mathbf{m} a zwycięzcą \mathbf{k}

SAMOUCZENIE SIECI METODĄ KOHONENA

ZASADA RYWALIZACJI:

Zwycięzca bierze wszystko

WINNER TAKES ALL (WTA)

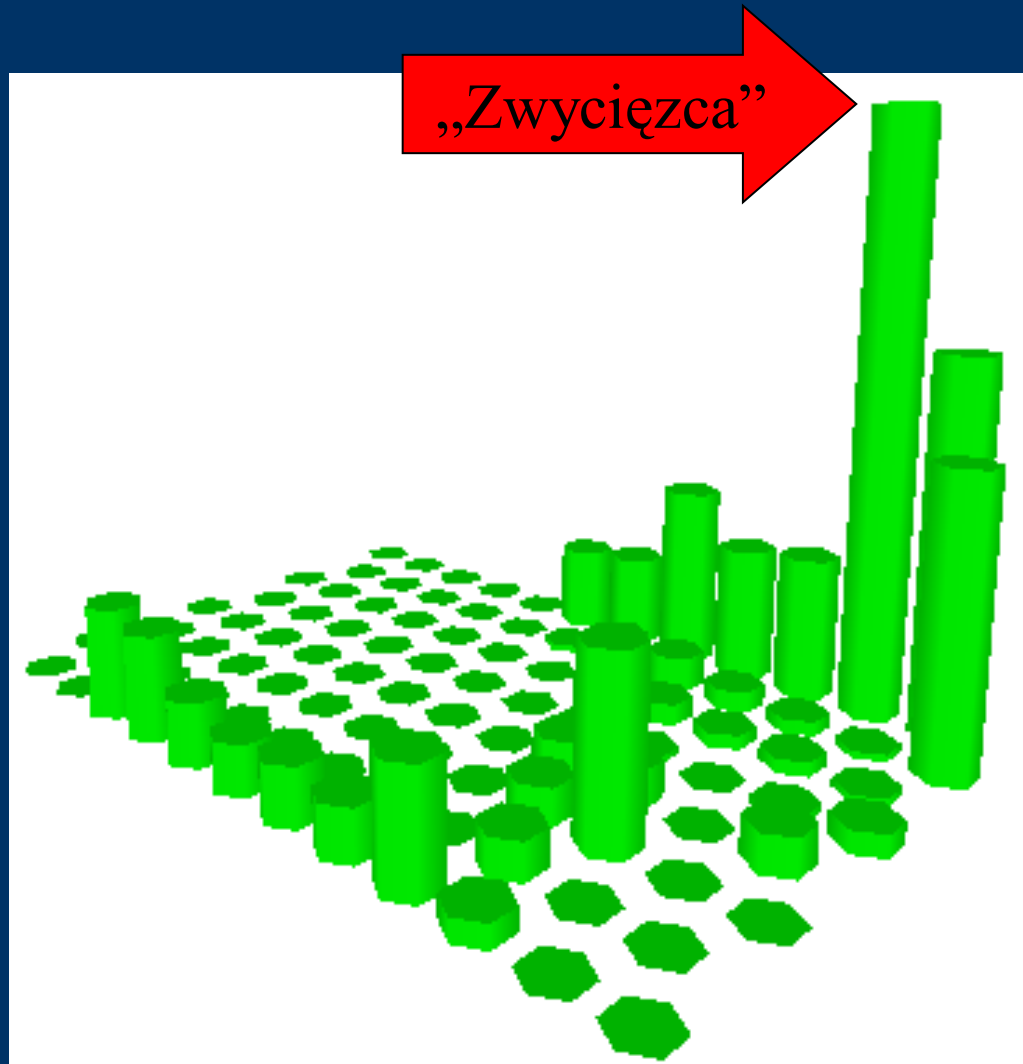
jesli wprowadzimy sąsiedztwo

to obowiązuje zasada:


Zwycięzca bierze większość

WINNER TAKES MOST (WTM)


Po nauczeniu sieć na wejściowy sygnał daje odpowiedź w postaci rozkładu pobudzeń neuronów warstwy topologicznej




Interpretacja tej odpowiedzi musi być jednak dopasowana do znanych przypadków



Neurony, które rozpoznają pojawianie się punktów z poszczególnych podobszarów przestrzeni sygnałów wejściowych




Podczas samouczenia położenie wektora wag neuronu może ulegać częstym zmianom, ale w ostatecznym efekcie tego „myszkania” neuron lokuje się w samym środku grupy reprezentowanych danych wejściowych.

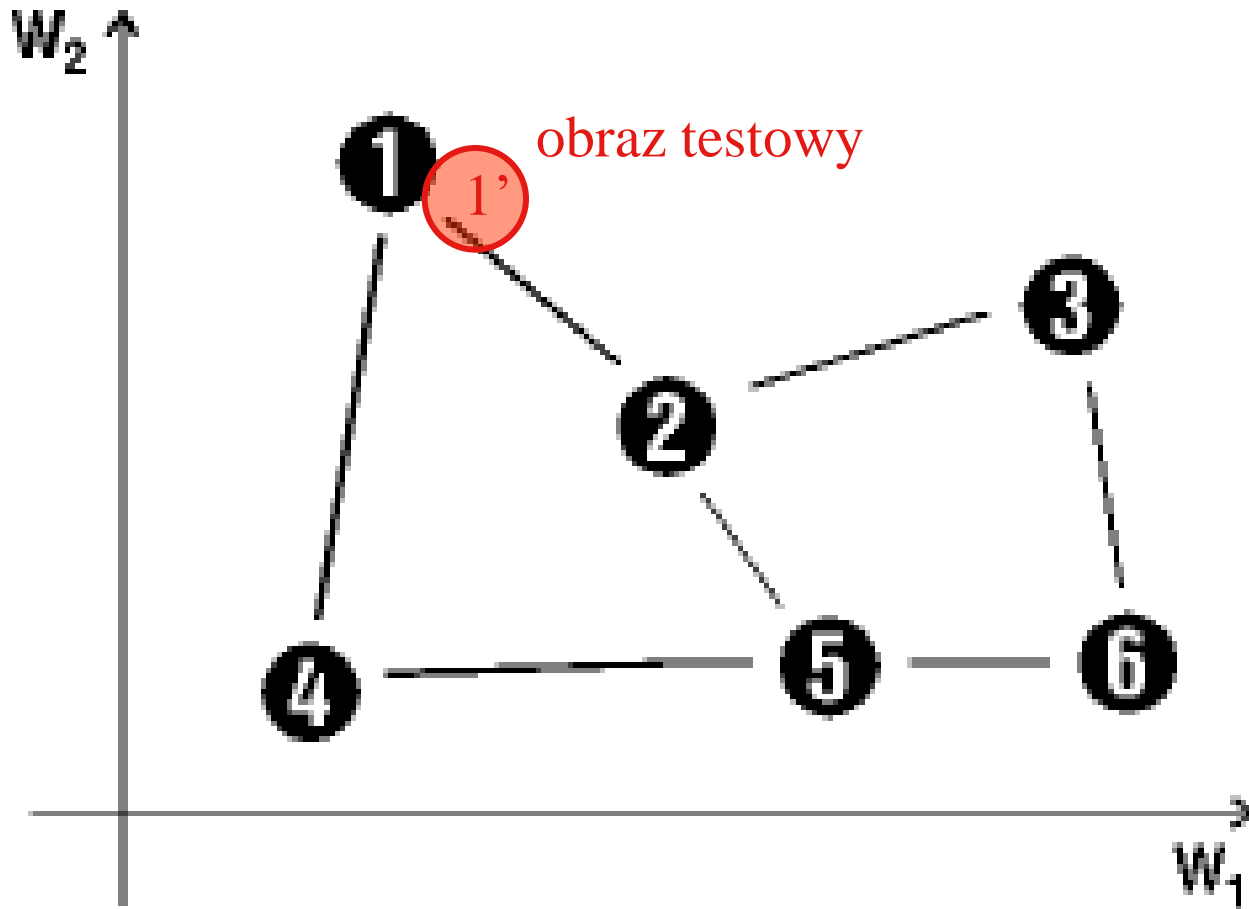


PRZYKŁAD ZASTOSOWANIA SIECI KOHONENA

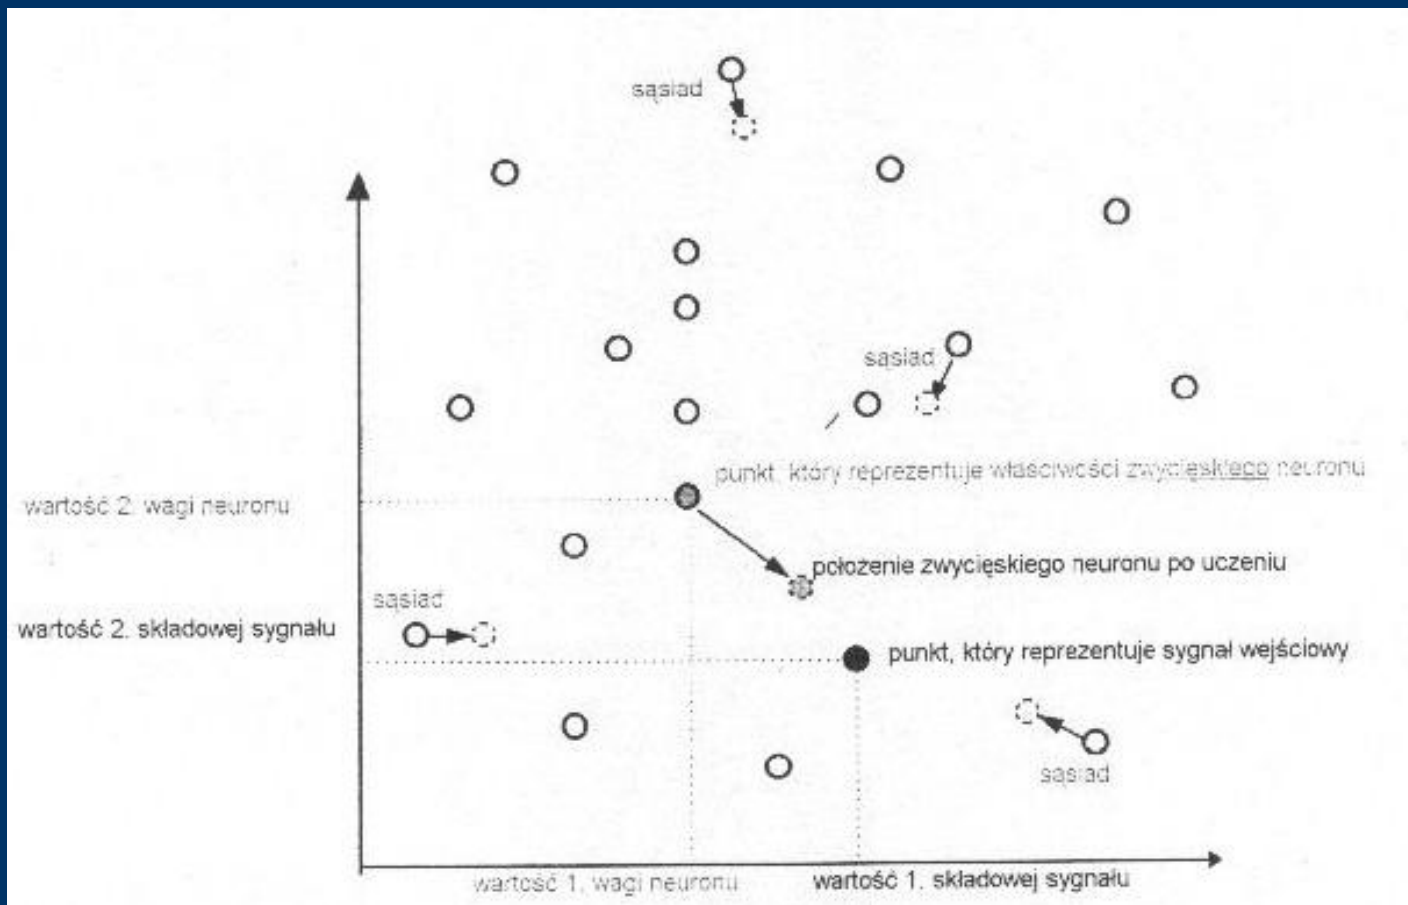
Obrazy wejściowe (tylko 2 cechy)



WAGI PO NAUCZENIU SIECI

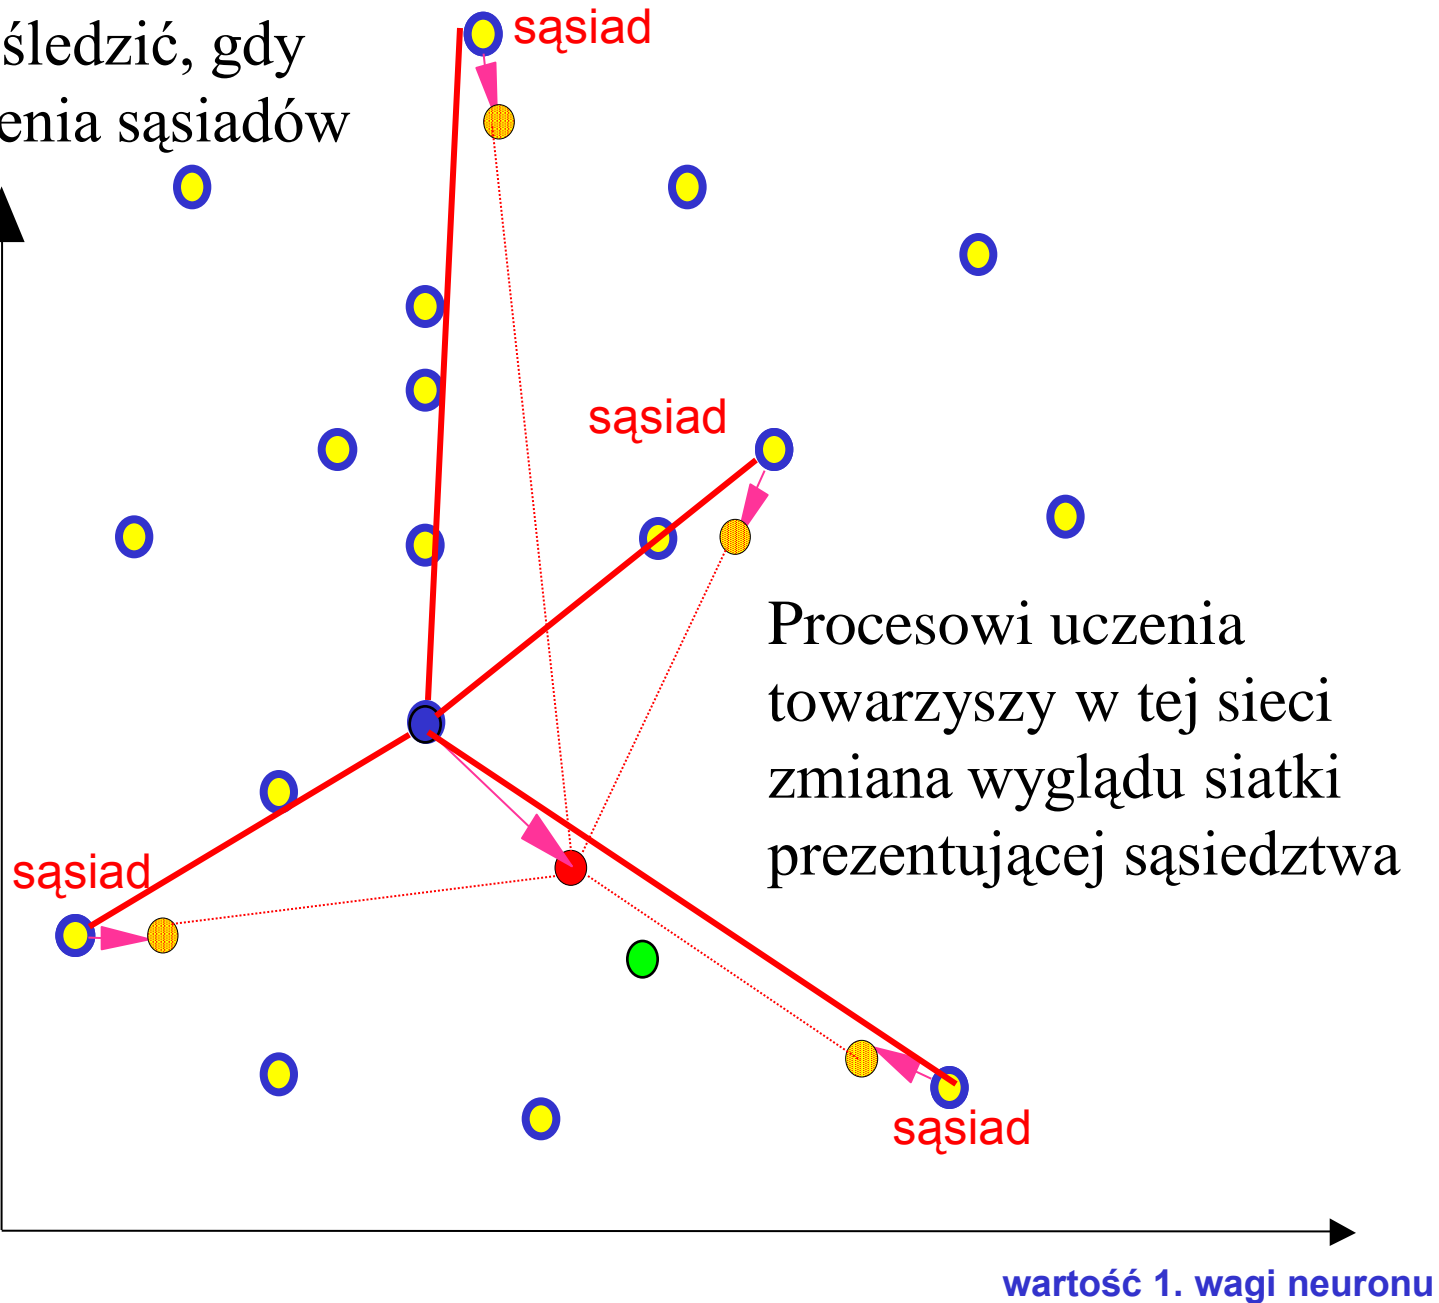


PRZEBIEG UCZENIA W SIECI KOHONENA

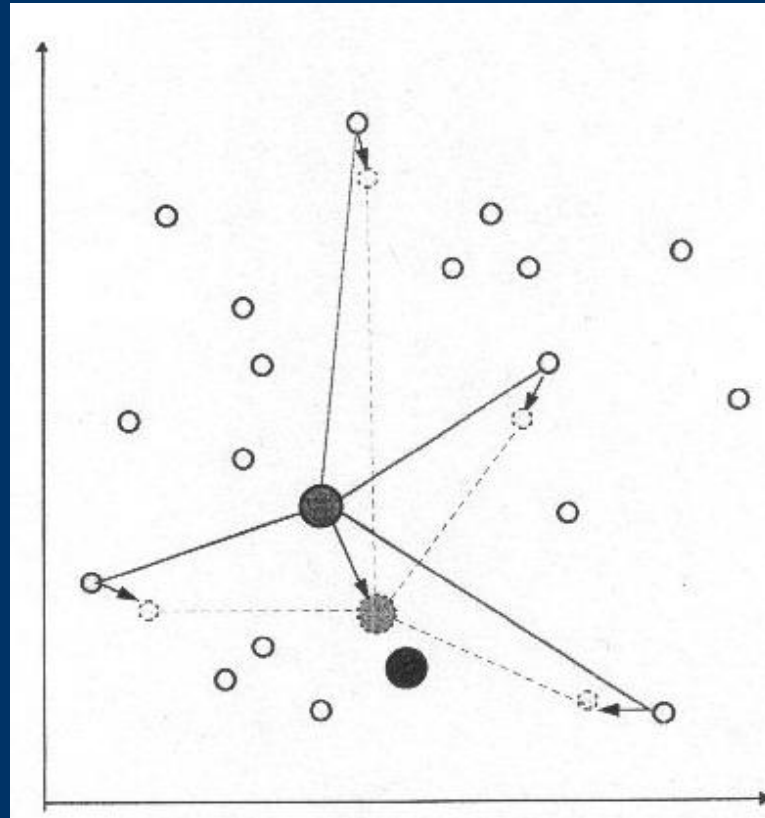


Ten sam proces uczenia można
będzie lepiej prześledzić, gdy
połączy się położenia sąsiadów

wartość 2.
wagi
neuronu




SAMOUCZENIE SIECI METODĄ KOHONENA




Sposób oznaczania sąsiednich neuronów podczas prezentacji uczenia sieci Kohonena.

SĄSIEDZTWO JEDNOWYMIAROWE




Sąsiedztwo jednowymiarowe

RODZAJE SĄSIEDZTWA DWUWYMIAROWEGO

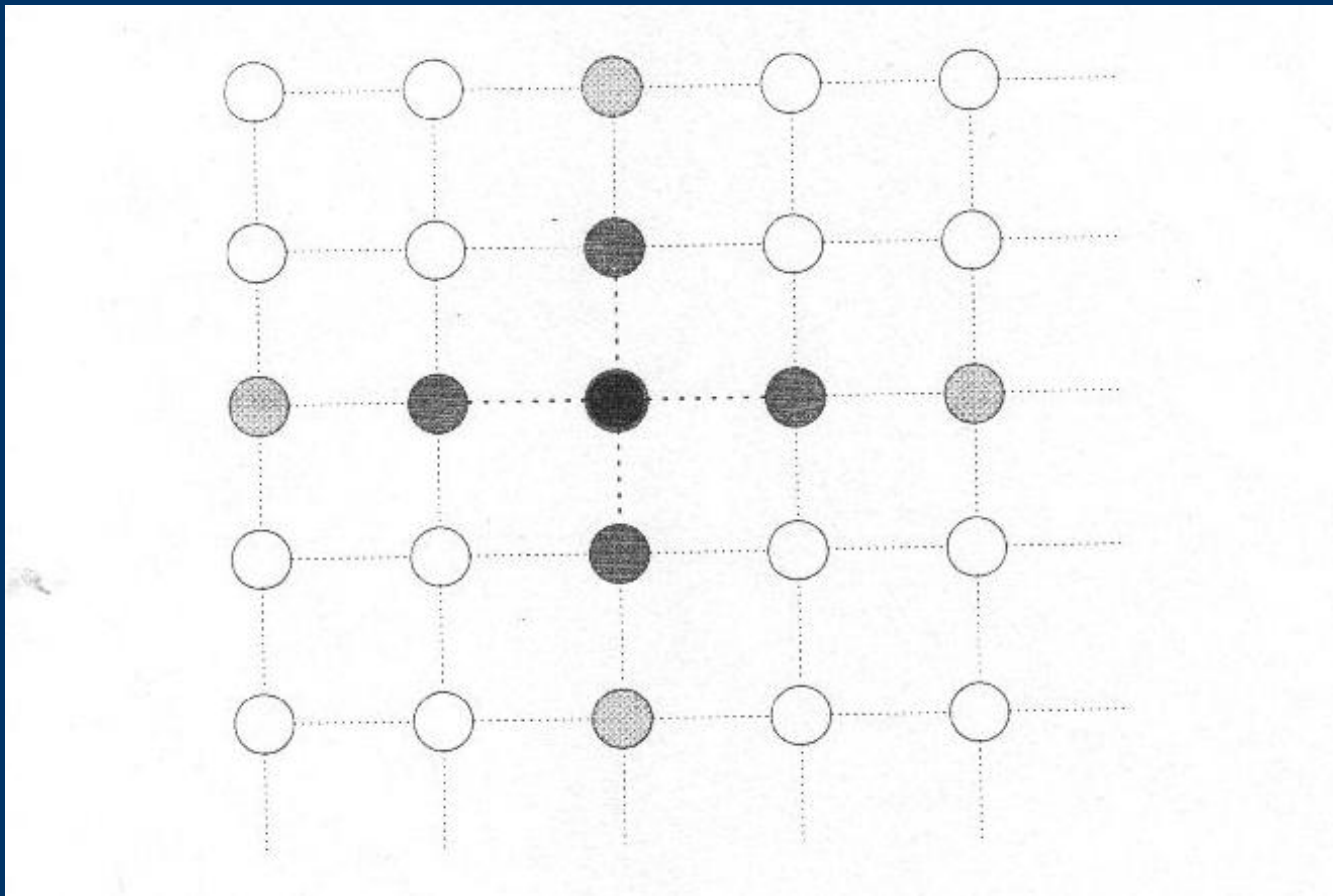


Neuron i jego sąsiedzi w sieci Kohonena




Rozbudowane sąsiedztwo w sieci Kohonena


RODZAJE SĄSIEDZTWA DWUWYMIAROWEGO




SĄSIEDZTWO DWUWYMIAROWE




0




20




100



1000




5000




100000

SĄSIEDZTWO JEDNOWYMIAROWE




Opisane zjawisko zostało wykryte przez samego Kohonena

Mapa topologiczna o podobnej strukturze, jak mapy tworzone przez sieci Kohonena, powstaje w korze mózgowej człowieka w obszarze czucia somatycznego oraz sterowania.




Obszary rejestrujące doznania czucia



Obszary sterujące ruchem

Podobnie jak w sieci Kohonena w obszarach otaczających bruzdę Rolanda na powierzchni kory mózgowej wytwarza się mapa topologiczna sygnałów z całego ciała. Obszary z których pochodzi więcej sygnałów zajmują więcej miejsca (angażują więcej neuronów), nawet jeśli anatomicznie są małe.




Takie proporcje ma ciało człowieka, jeśli brać pod uwagę wielkość struktur nerwowych związanych ze sterowaniem poszczególnymi częściami ciała



SĄSIEDZTWO JEDNOWYMIAROWE

Punkty reprezentujące podobne sygnały wejściowe


Sąsiednie neurony rozpoznające podobne sygnały wejściowe



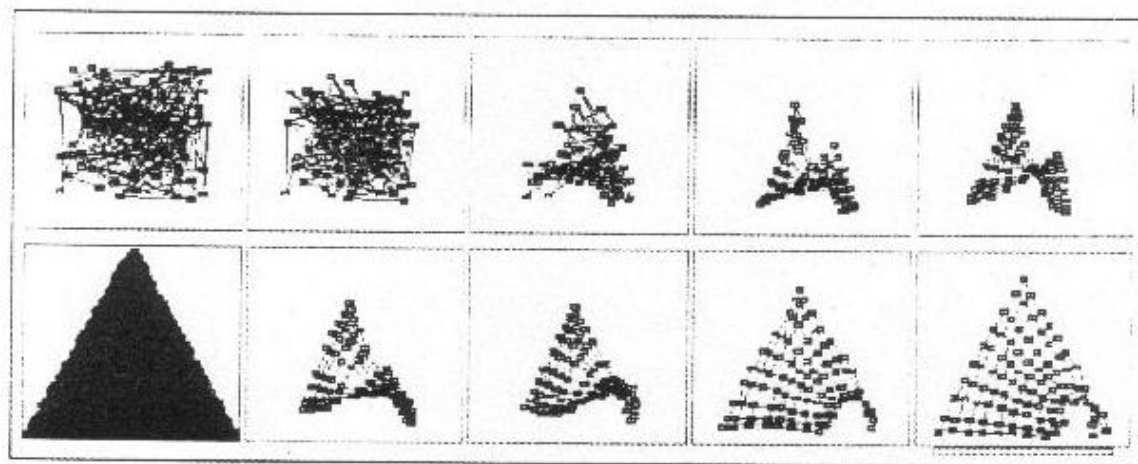
Punkty reprezentujące podobne sygnały wejściowe

Odległe neurony rozpoznające podobne sygnały wejściowe

MAPY KOHONENA




Rys. 10.20. Przykład trudności w uzyskiwaniu skutecznej samoorganizacji występujących w przypadku zbyt dużego rozrzutu początkowych wartości współczynników wag neuronów.




Rys. 10.21. Przykład ignorowania części danych wejściowych, występujący niekiedy w przypadku zbyt dużego rozrzutu początkowych wartości współczynników wag neuronów.

ZJAWISKO “SKRĘCENIA” W SIECI KOHONENA



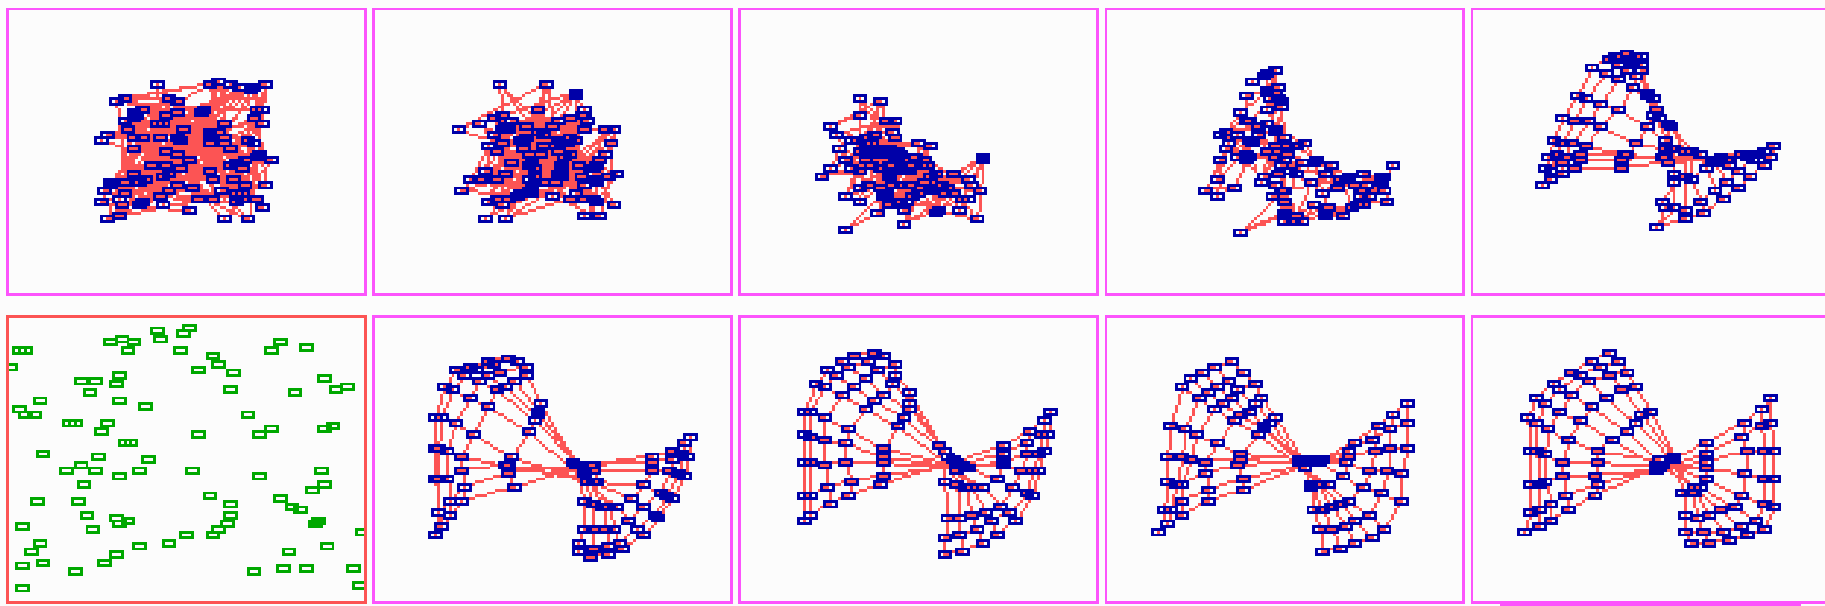
Część danych wejściowych została
zignorowana!


ZJAWISKO “SKRĘCENIA” W SIECI KOHONENA



Rzadko występujący przypadek “skręcenia się” sieci Kohonena odtwarzającej obszar w przestrzeni sygnałów wejściowych w postaci krzyża

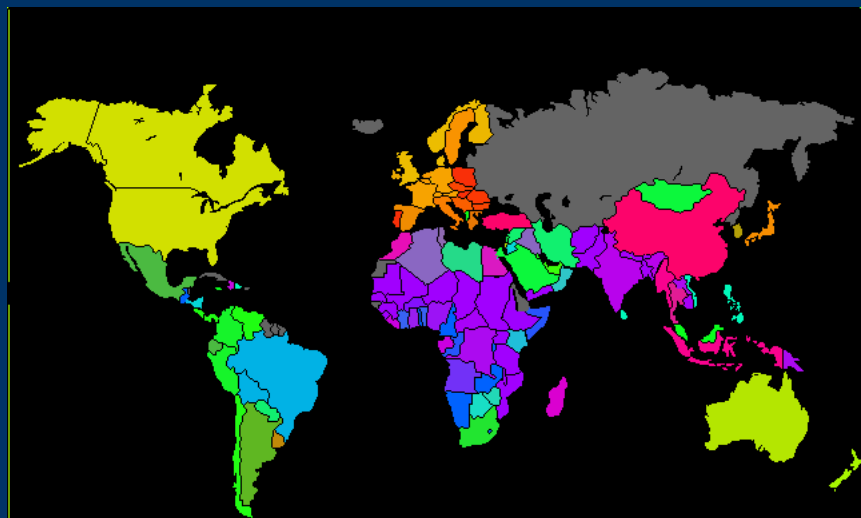
ZJAWISKO “SKRĘCENIA” W SIECI KOHONENA





Grupowaniu w sieci Kohonena mogą podlegać kraje świata

<http://www.cis.hut.fi/research/som-research/worldmap.html>



World Poverty Map


Samorganizujące Mapa (SOM) mogą być wykorzystywane do przedstawiania skomplikowanych korelacji w danych statystycznych. Oto dane składające się z danych statystycznych Banku Światowego krajów w 1992 roku. W sumie zostało wykorzystanych 39 wskaźników opisujących różne wskaźniki jakości, takie jak stan zdrowia, odżywiania, usługi edukacyjne, itp. Kraje, które miały podobne wartości wskaźników znalazł się blisko siebie na mapie. Poszczególne gromady na mapie zostały automatycznie kodowane w różnych kolorach, tak, żeby kolory płynnie zmieniały się na ekranie mapy. W wyniku tego procesu, do każdego kraju był w rzeczywistości automatycznie przypisany kolor opisujący jego rodzaj ubóstwa w stosunku do innych krajów.

The Country Names

AFG	Afghanistan	GTM	Guatemala	NZL	New Zealand
AGO	Angola	HKG	Hong Kong	QAN	Taiwan, China
ALB	Albania	IND	Indonesia	OMN	Oman
ARE	United Arab Emirates	ITF	Italy	PAK	Pakistan
ARG	Argentina	HUN	Hungary	PAN	Panama
AUS	Australia	IVC	Ivory Coast	PER	Peru
AUT	Austria	IDN	Indonesia	PHL	Philippines
BDI	Burundi	IND	India	PNG	Papua New Guinea
BEL	Belgium	IRL	Ireland	POL	Poland
BDN	Benin	IRN	Iran, Islamic Rep.	PRT	Portugal
BGD	Bangladesh	IRQ	Iraq	PRY	Paraguay
BGR	Bulgaria	ISR	Israel	ROM	Romania
BOL	Bolivia	ITA	Italy	RWA	Rwanda
BRA	Brazil	JAM	Jamaica	SAT	Saudi Arabia
BTK	Bhutan	JOR	Jordan	SDN	Sudan
BLR	Myanmar	JPN	Japan	SEN	Senegal
BWA	Botswana	KEN	Kenya	SGP	Singapore
CAP	Central African Rep.	KHM	Cambodia	SLR	Sierra Leone
CAN	Canada	KOR	Korea, Rep.	SLV	El Salvador
CHE	Switzerland	KWT	Kuwait	SOM	Somalia
CHL	Chile	LAO	Laos PDR	SWE	Sweden
CHN	China	LBN	Lebanon	SYR	Syrian Arab Rep.

CTV	Cote d'Ivoire	LBR	Liberia	TCD	Chad
CMR	Cameroon	LDY	Libya	TGO	Togo
COG	Congo	LKA	Sri Lanka	THA	Thailand
COL	Colombia	LSO	Lesotho	TTO	Trinidad and Tobago
CRI	Costa Rica	MAR	Marocco	TUN	Tunisia
CSK	Czechoslovakia	MDG	Madagascar	TUR	Turkey
DEU	Germany	MEX	Mexico	TZA	Tanzania
DNK	Denmark	MLI	Mali	UGA	Uganda
DOM	Dominican Rep.	MNG	Mongolia	URY	Uruguay
DZA	Algeria	MUZ	Mozambique	USA	United States
ECU	Ecuador	MRT	Mauritania	VEN	Venezuela
EGY	Egypt, Arab Rep.	MUS	Mauritius	VNM	Viet Nam
ESP	Spain	MWI	Malawi	YEM	Yemen, Rep.
ETH	Ethiopia	MYA	Malaysia	YUG	Yugoslavia
FIN	Finland	NAM	Namibia	ZAF	South Africa
FRA	France	NER	Niger	ZAR	Zaire
GAB	Gabon	NGA	Nigeria	ZMB	Zambia
GBR	United Kingdom	NIC	Nicaragua	ZWE	Zimbabwe
GHA	Ghana	NLD	Netherlands		
GIN	Guinea	NOR	Norway		
GRD	Greece	NPL	Nepal		


ZMIANA CELÓW SAMOORGANIZACJI W TRAKCIE UCZENIA SIECI




*WYMIAR SIECI A
WYMIAR PRZESTRZENI
SYGNAŁÓW
WEJŚCIOWYCH*

We wszystkich wyżej podawanych przykładach wymiar przestrzeni sygnałów i wymiar struktury sieci były zgodne

Dwuwymiarowa struktura sieci



Dwuwymiarowa przestrzeń sygnałów




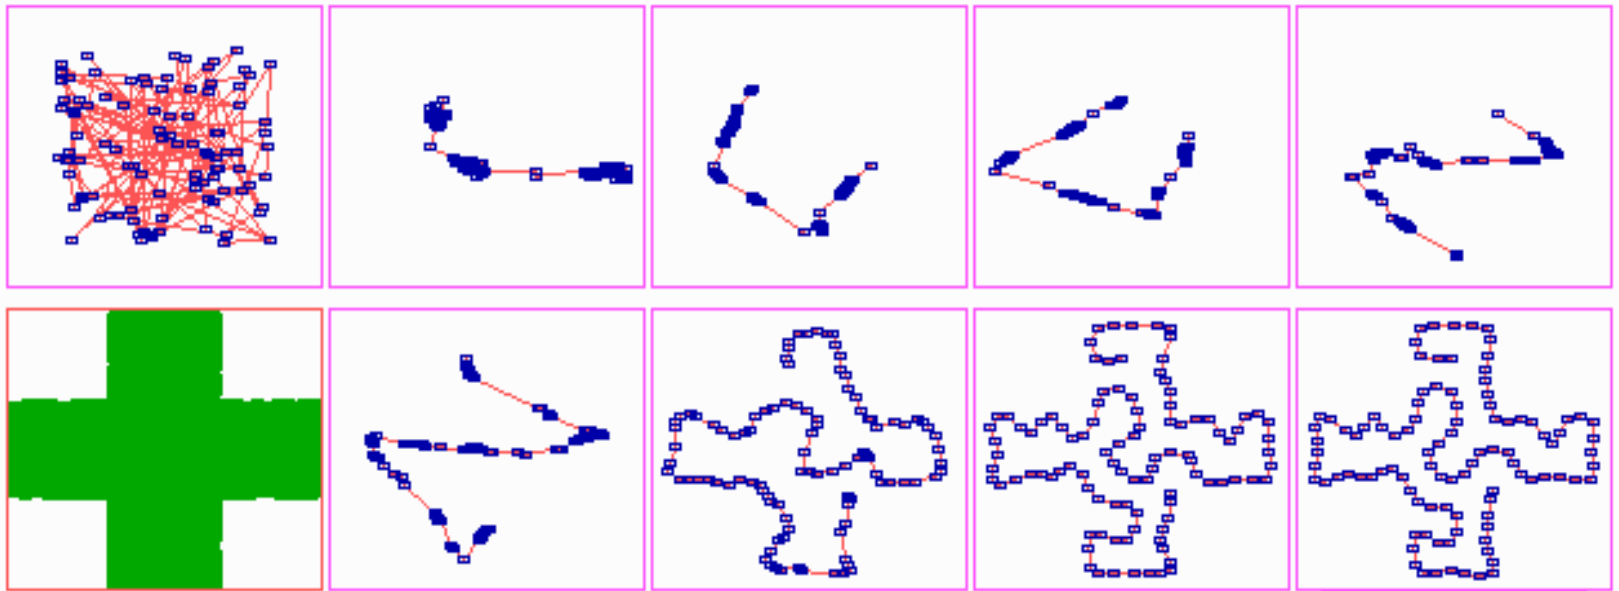
Można jednak pokazać przykład sieci, w której wymiar przestrzeni wejściowej jest inny niż wymiar topologii sieci

Jednowymiarowa struktura sieci




Dwuwymiarowa przestrzeń sygnałów






MAPY KOHONENA





Zjawisko “skręcenia się” sieci Kohonena (3)



Rzadko występujący przypadek “skręcania się” sieci Kohonena odtwarzającej obszar w przestrzeni sygnałów wejściowych w postaci krzyża

**Niekiedy obszar
pokrywany
przez sieć
Kohonena może
być dosyć
skomplikowany
w kształcie**



Wniosek

Sieć Kohonena może służyć do tego, żeby przy jej pomocy „rzutować” wielowymiarowe zbiory danych do przestrzeni o małej wymiarowości.

MECHANIZM SUMIENIA

(lub zmęczenia neuronu)

Mechanizm sumienia - część neuronów może nie znaleźć się w strefie wpływu neuronów wygrywających i tym samym może nie zmienić swoich początkowych wag (nie uczestniczy w procesie uczenia).

Neurony często wygrywające pozwalają wygrywać innym

Np. wprowadzamy potencjał p_i

$$p_i \rightarrow \begin{cases} p_i + \frac{1}{N} \bmod 1 & i \neq w \\ p_i - p_{min} & i = w \end{cases}$$

Zwyciezca wybierany jest tylko z neuronów dla których $p_i > p_{min}$

$$d(x, t_w) = \min\{d(x, t_i) : p_i > p_{min}\}$$

47	47	55	55	55	37	57	57	57	12	12	24	24	24
47	47	49	55	36	36	36	57	12	11	11	24	24	17
48	48	49	49	36	36	25	25	11	11	11	14	17	17
48	48	49	53	10	25	25	25	3	11	14	14	14	17
62	62	46	10	10	33	25	3	3	3	16	14	2	2
62	62	46	35	33	33	33	59	18	16	16	18	9	9
62	62	35	35	35	33	43	29	13	6	22	22	18	18
60	60	60	61	59	61	15	15	29	54	54	22	34	18
63	63	60	44	61	61	61	15	28	54	9	27	27	7
42	60	66	66	32	58	58	61	20	20	20	27	8	8
42	42	66	32	32	32	65	65	52	20	4	4	26	26
42	56	40	40	32	38	38	65	52	41	19	19	1	4
30	45	50	31	31	56	56	39	52	41	28	1	1	1
30	45	50	31	31	31	56	56	39	41	28	28	5	5



obszar bezpieczny




obszar bankructwa

Grupowanie banków – wynik działania sieci Kohonena

(w zależności od wskaźników finansowych)


Mapa cech przedsiębiorstw uzyskana z pomocą sieci Kohonena



PODSUMOWANIE

Struktura sieci Kohonena

Warstwa topologiczna




Warstwa
wejściowa

Cechy charakterystyczne:

- sieć uczy się bez nauczyciela
- sieć ma dwie warstwy o wyraźnie rozdzielonych funkcjach
- uporządkowane neurony wyjściowe
- uczony głównie neuron „zwycięski”
- ważną rolę odgrywa „sąsiedztwo”
- w wyniku uczenia powstaje mapa topologiczna
- aprioryczna interpretacja wartości wyjściowych jest niemożliwa,
- po uczeniu można ustalić, jakie znaczenie mają poszczególne rejony mapy topologicznej - ale wyłącznie na podstawie analizy konkretnych przykładów danych wejściowych

ZASTOSOWANIA SIECI KOHONENA

- Rozpoznawanie obrazów
- Klasyfikacja
- Zgłębianie danych
- Tworzenie modeli np.:
 - model świata zewnętrznego w „mózgu” robota
 - model uczciwego przedsiębiorcy
 - model działania procesu



LITERATURA

Tadeusiewicz Ryszard, *Sieci neuronowe*. W-wa 1993

Tadeusiewicz Ryszard, *Elementarne wprowadzenie do techniki sieci neuronowych z przykładowymi programami*. W-wa 1998