

METODY INŻYNIERII WIEDZY

KNOWLEDGE ENGINEERING AND DATA MINING



MODELOWANIE WIEDZY DLA ZBIORU SEKWENCJI UCZĄCYCH

Akademia Górniczo-Hutnicza

***Wydział Elektrotechniki, Automatyki, Informatyki i Inżynierii Biomedycznej
Katedra Automatyki i Inżynierii Biomedycznej, Laboratorium Biocybernetyki
30-059 Kraków, al. Mickiewicza 30, paw. C3/205***

horzyk@agh.edu.pl, Google: Adrian Horzyk



Adrian Horzyk



MONKEY

to przykład
zbioru faktów
opisujących
małpkę:



*"I have a **monkey**. My **monkey** is very small.
It is very lovely. It likes to sit on my head.
It can jump very quickly. It is also very clever.
It learns quickly. My **monkey** is lovely.
I have also a small dog."*

QUESTION: What is this monkey like?

KONSTRUKCJA ASOCJACYJNEGO GRAFU NEURONOWEGO DLA ZBIORU SEKWENCJI UCZĄCYCH:

- 1x S1 I HAVE A MONKEY
- 1x S2 MY MONKEY IS VERY SMALL
- 1x S3 IT IS VERY LOVELY
- 1x S4 IT LIKES TO SIT ON MY HEAD
- 1x S5 IT CAN JUMP VERY QUICKLY
- 1x S6 IT IS ALSO VERY CLEVER
- 1x S7 IT LEARNS QUICKLY
- 1x S8 MY MONKEY IS LOVELY
- 1x S9 I HAVE ALSO A SMALL DOG



ASOCJACYJNY GRAF NEURONOWY MONKEY



FPS: 63

Status OK

0

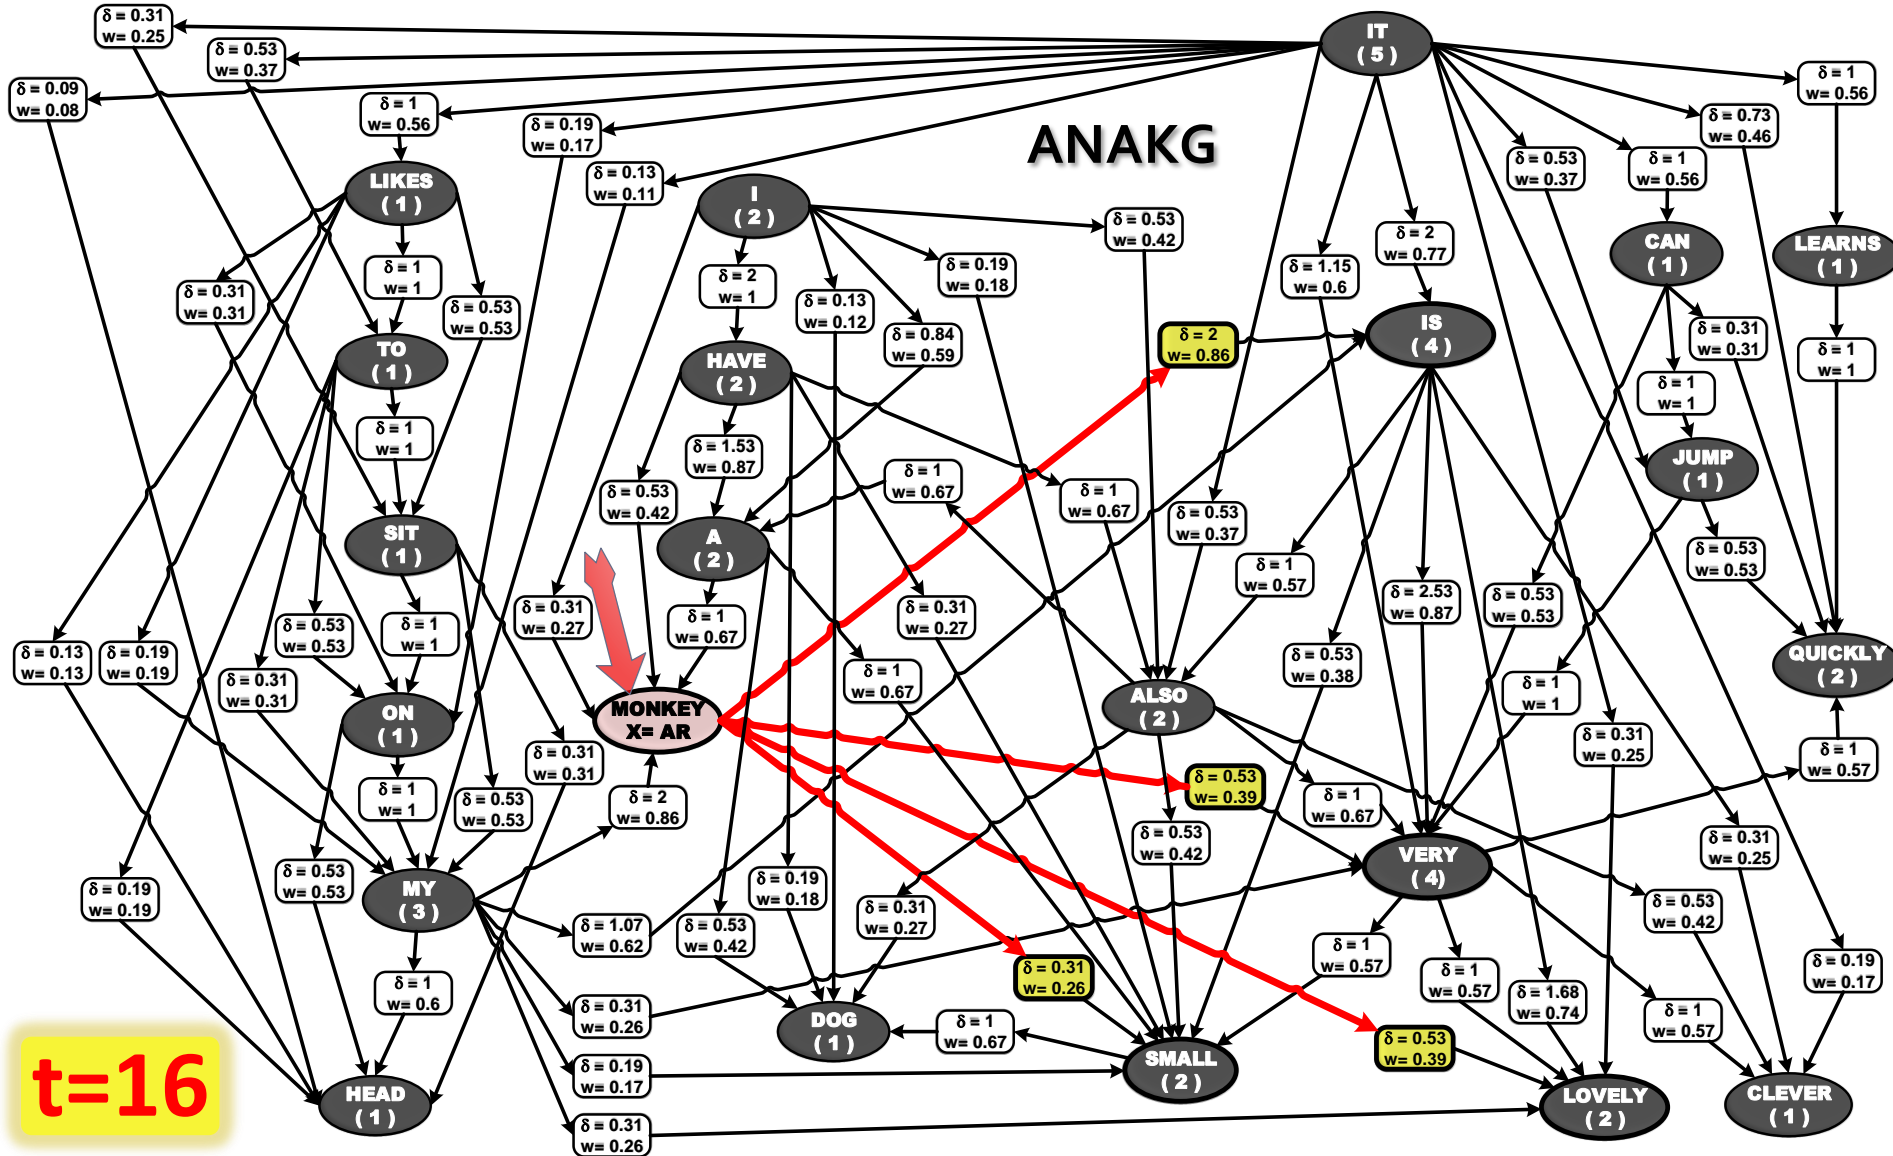


>>



ASSOCIATIVE NEURAL GRAPH ANAKG-2

Neuron **MONKEY** pobudza synapsy.

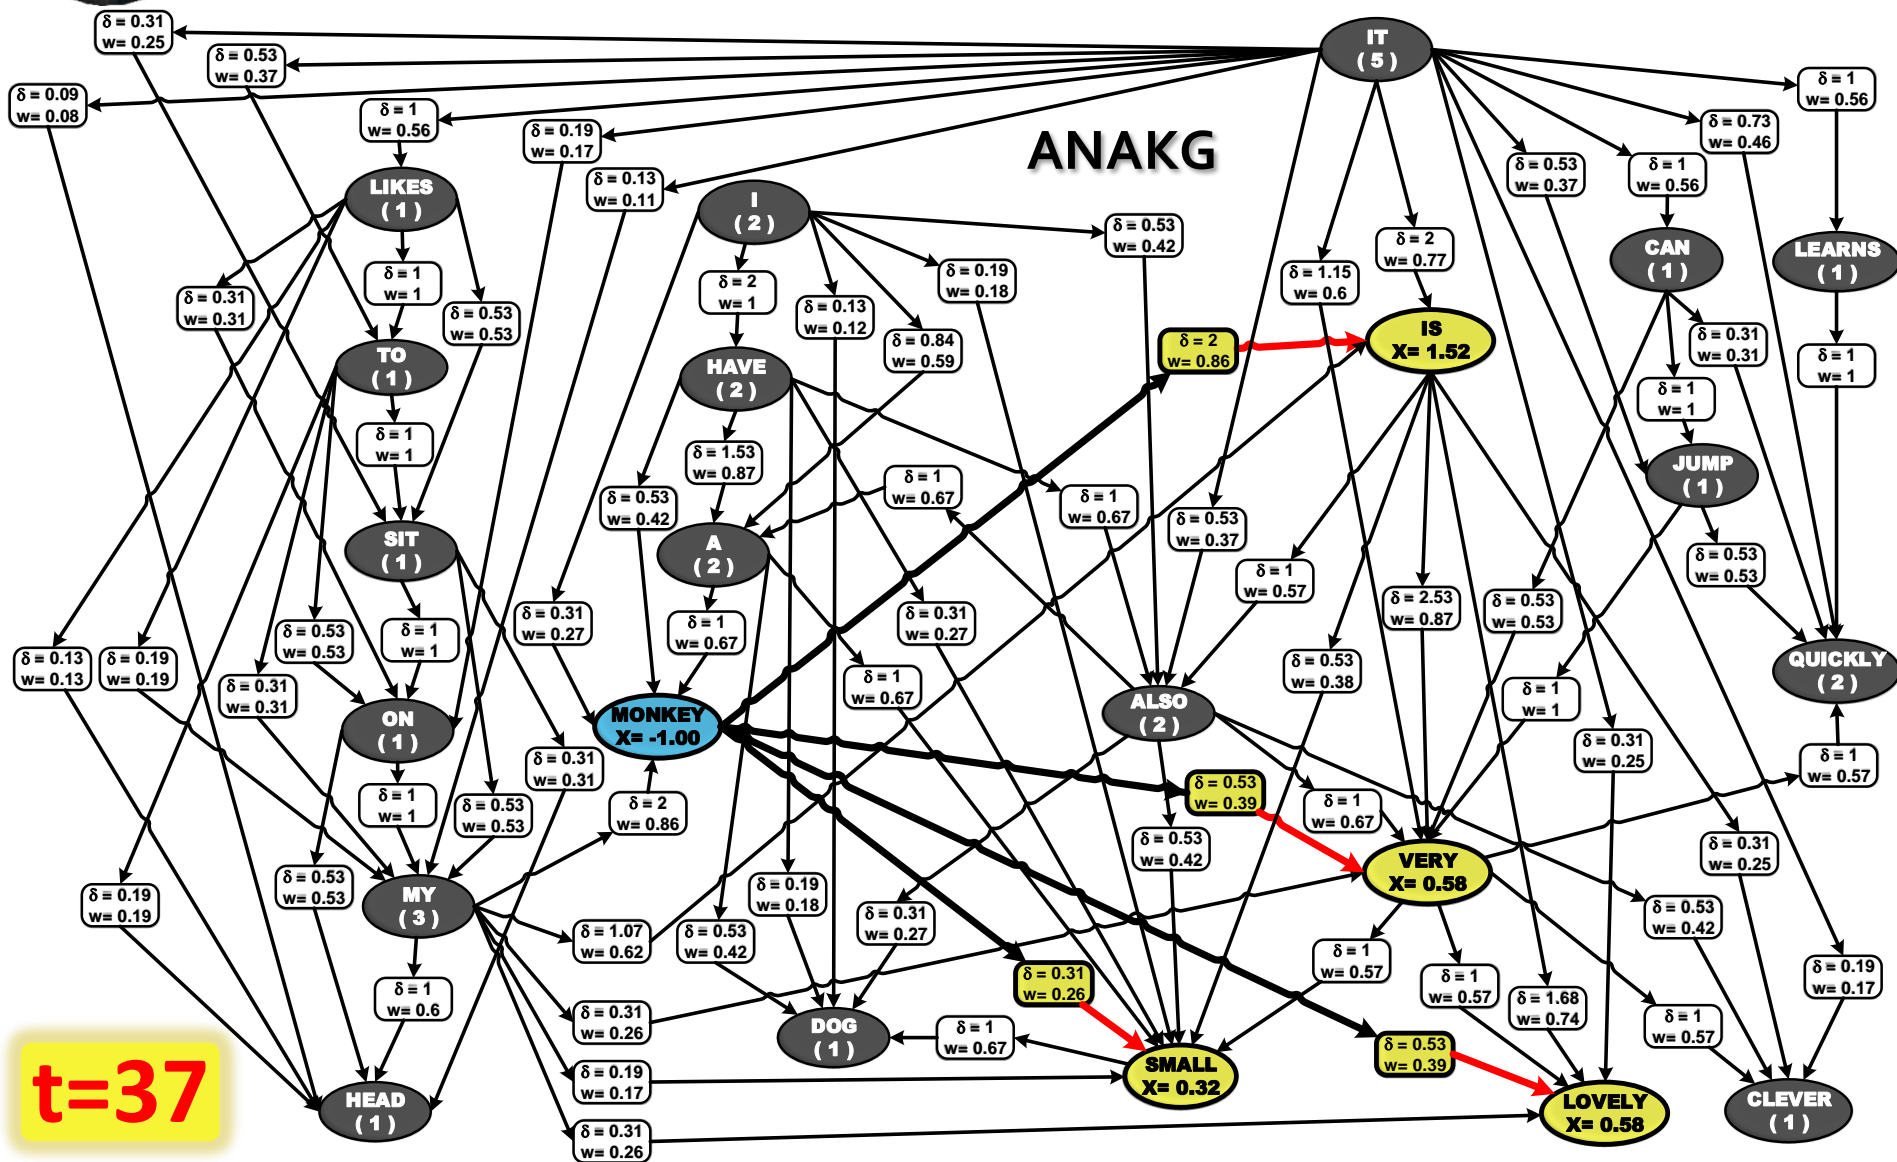


t=16



ASSOCIATIVE NEURAL GRAPH ANAKG-2

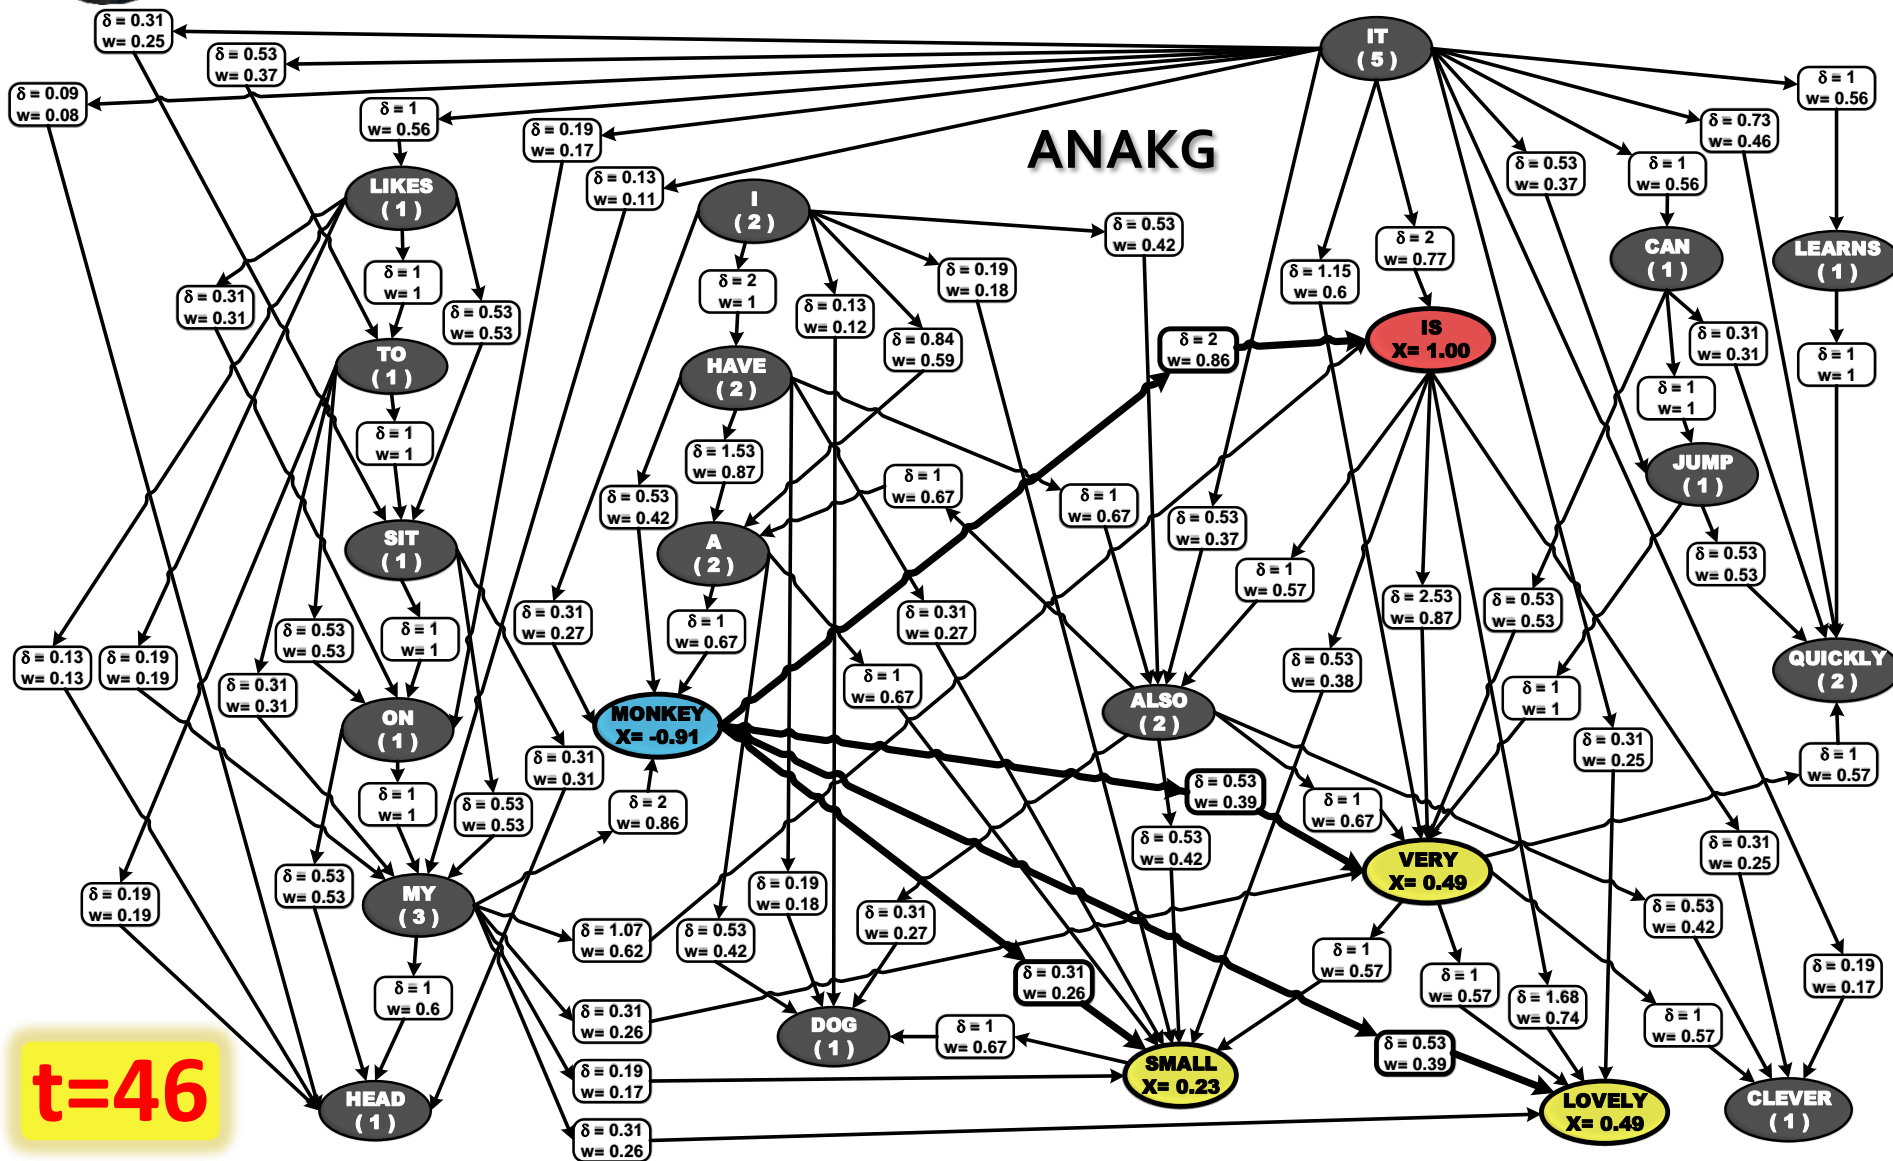
Neuron **MONKEY** po raz drugi pobudza neurony.





ASSOCIATIVE NEURAL GRAPH ANAKG-2

Na skutek tego neuron **IS** zostaje aktywowany.

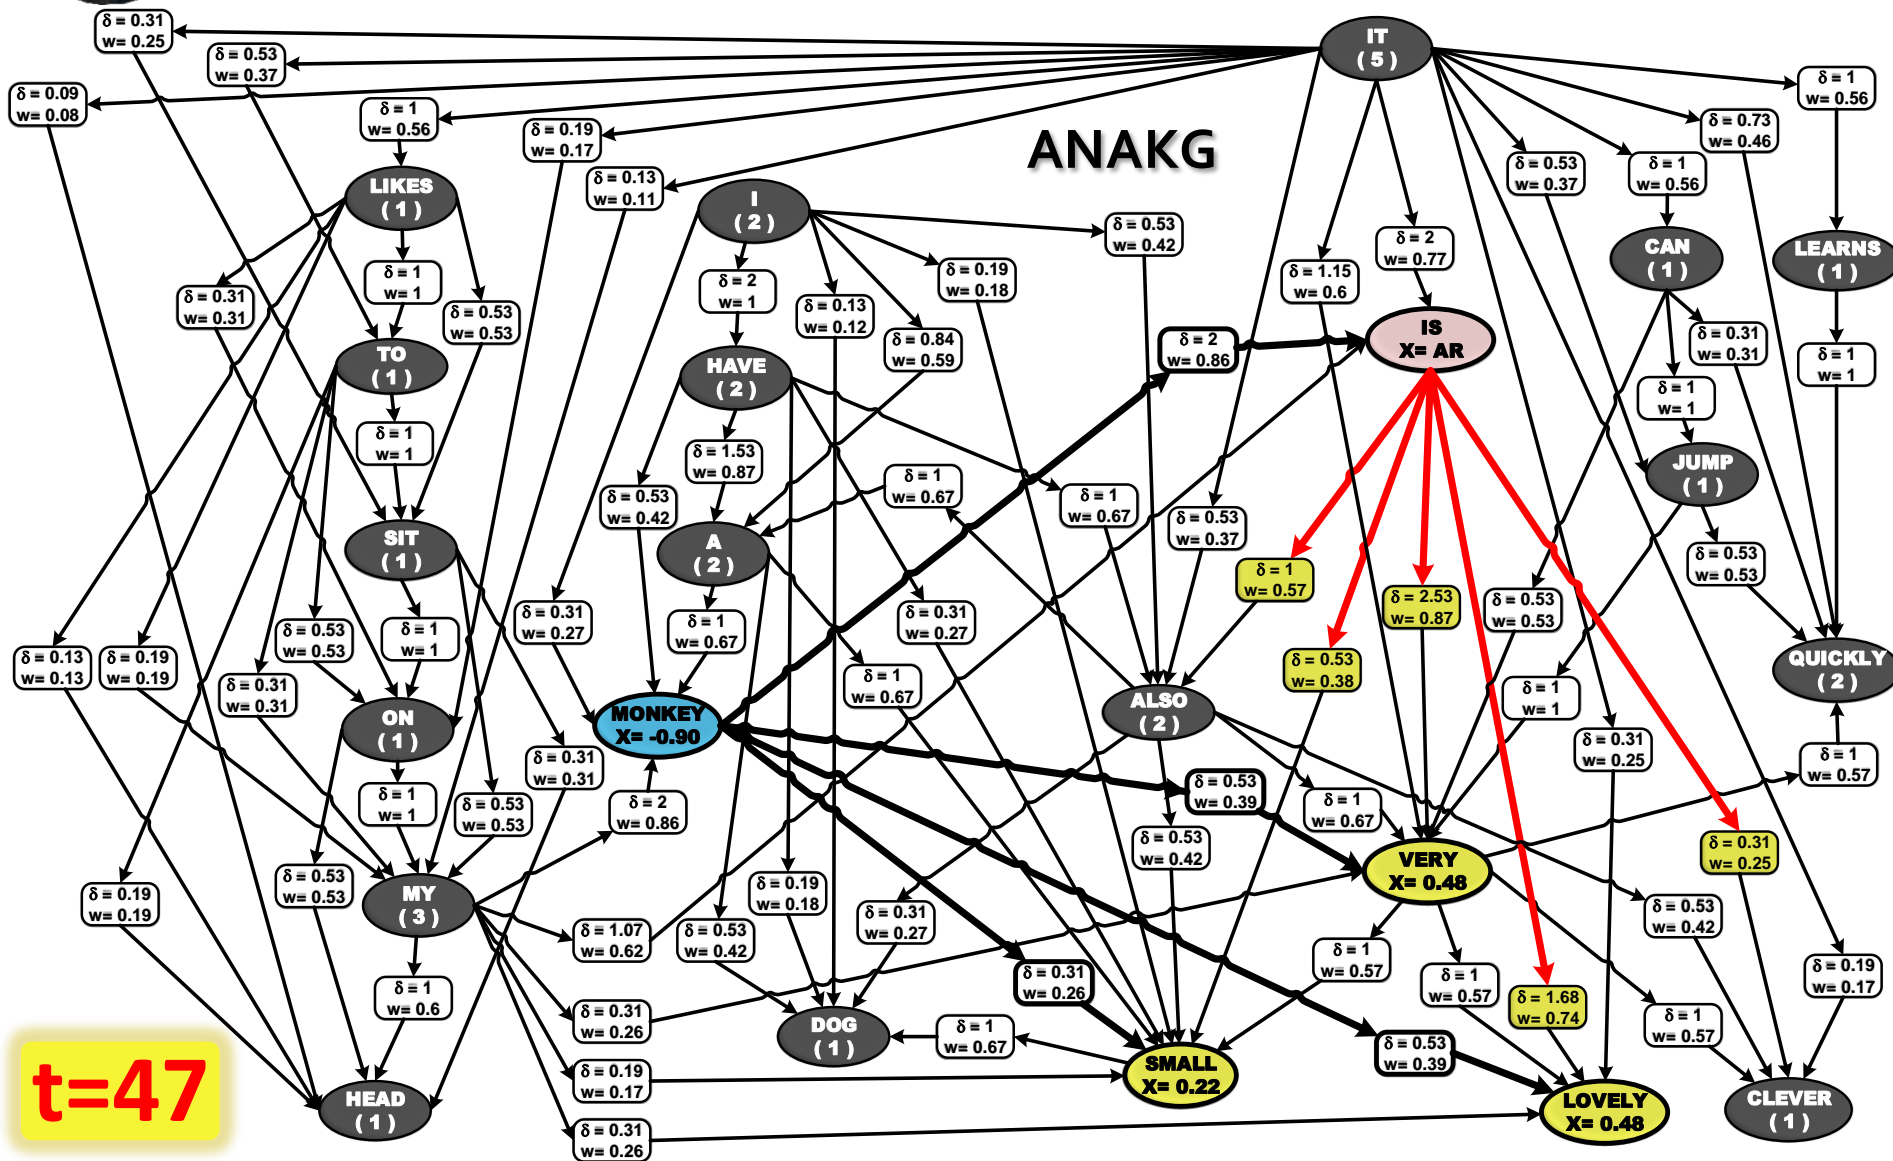


t=46



ASSOCIATIVE NEURAL GRAPH ANAKG-2

Neuron **IS** pobudza kolejne synapsy.

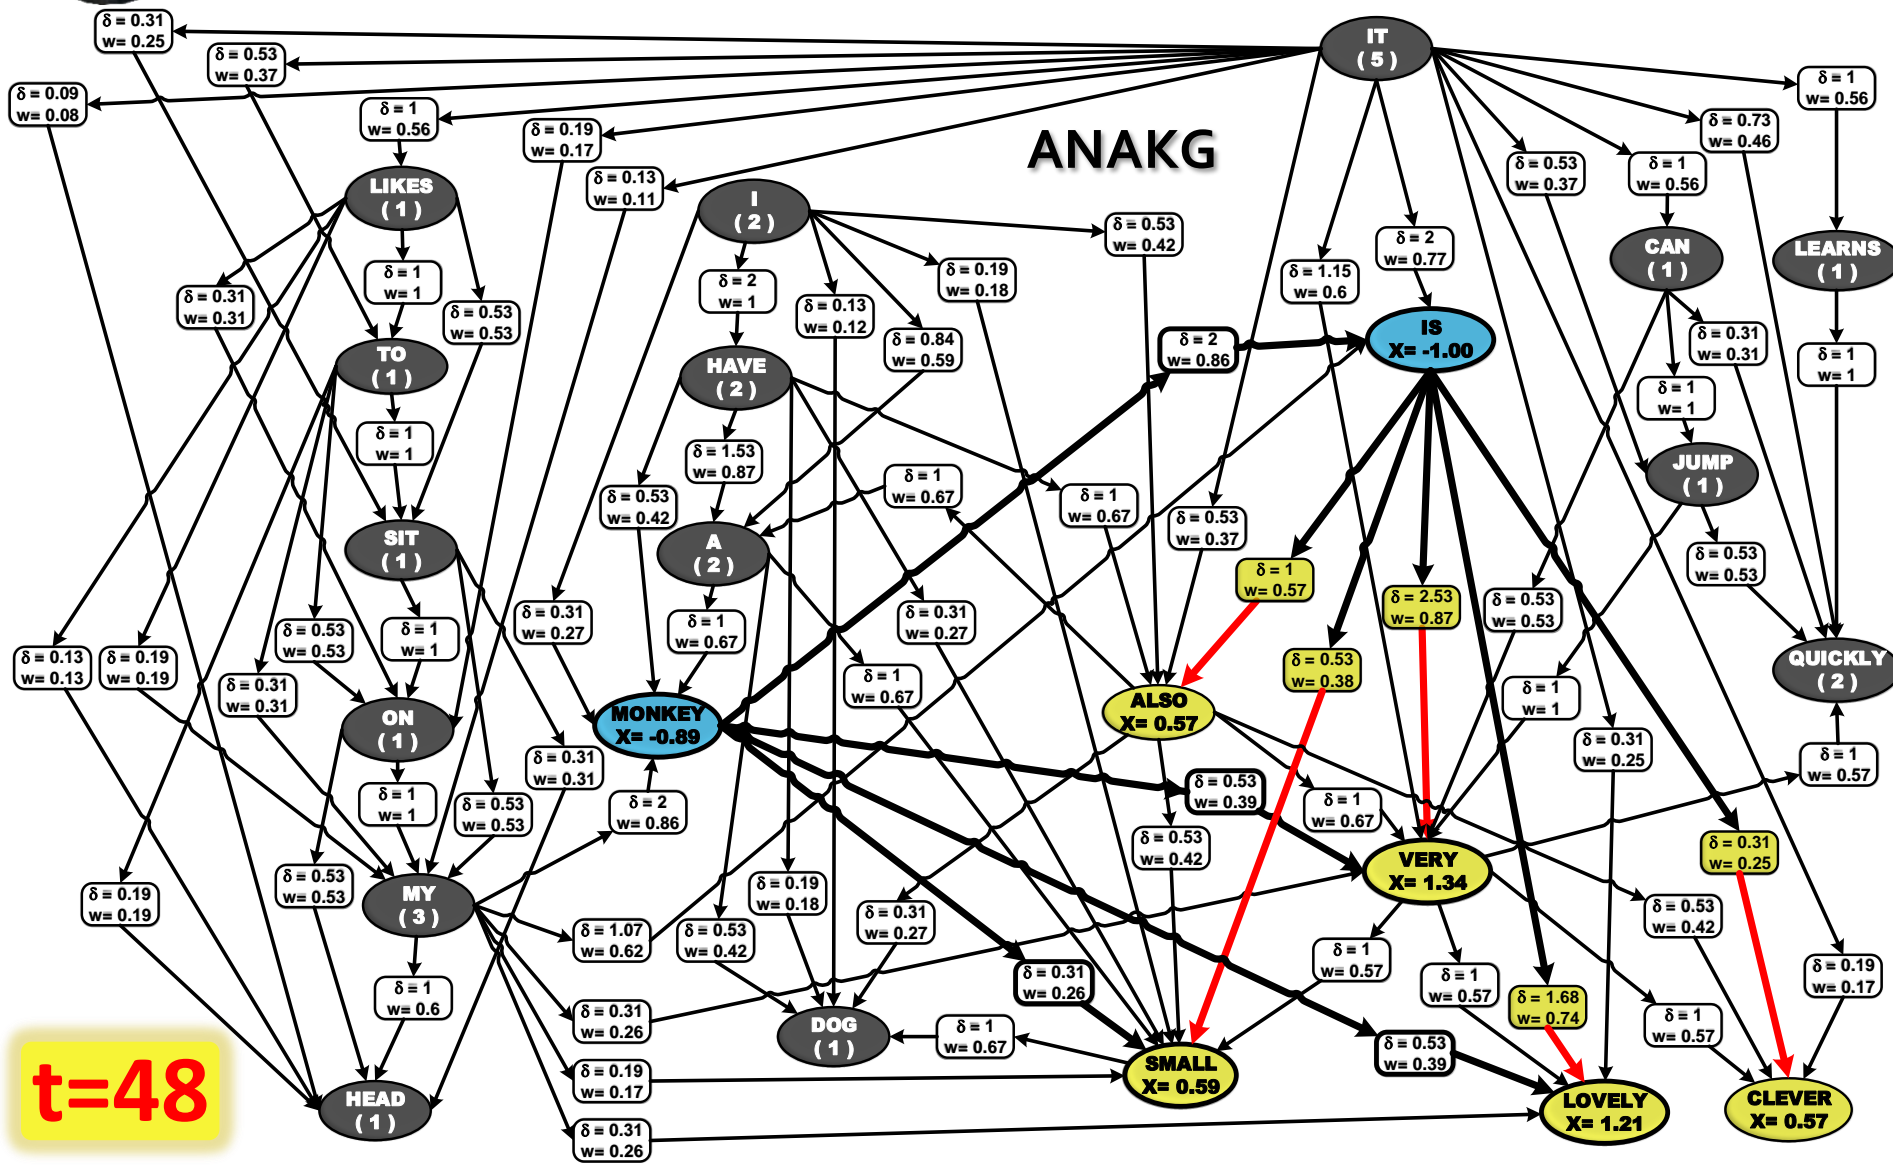


t=47



ASSOCIATIVE NEURAL GRAPH ANAKG-2

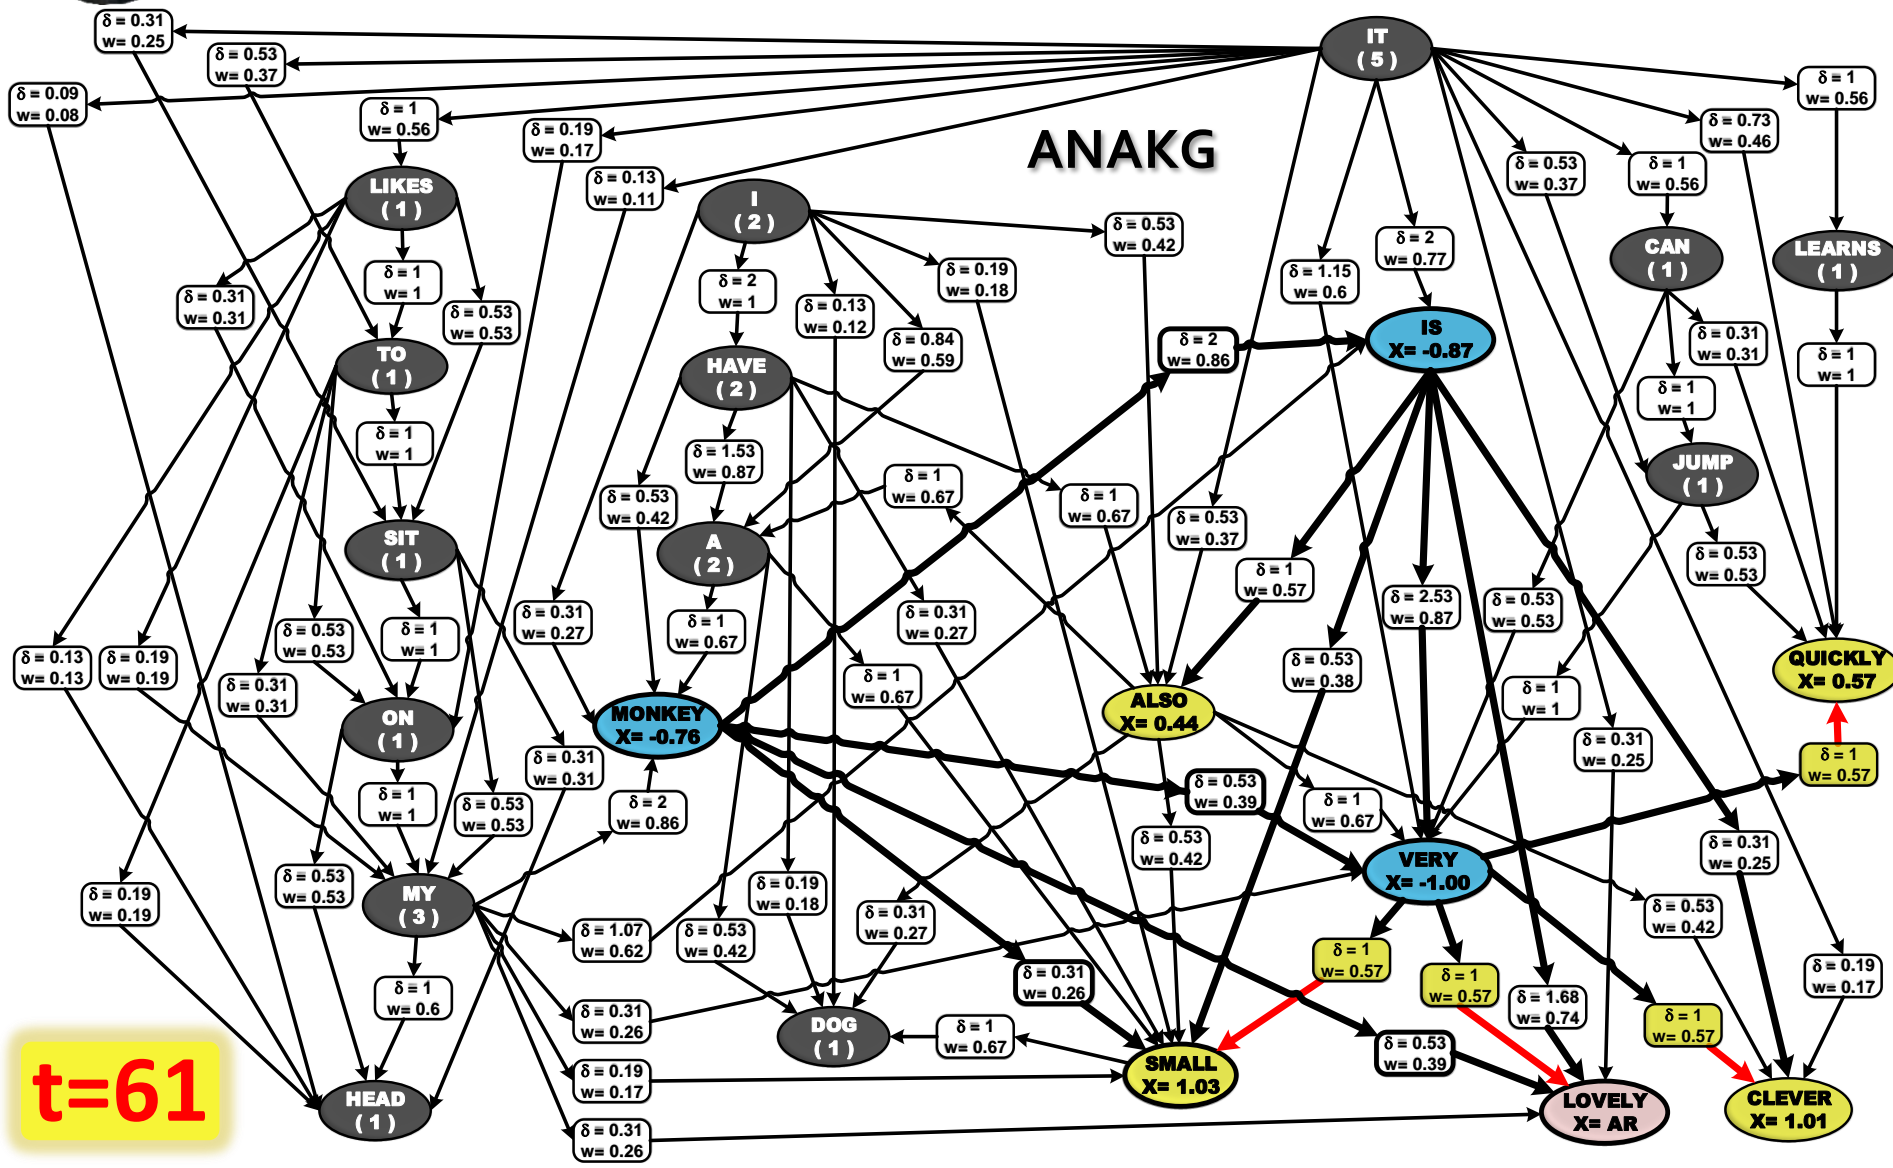
Neuron **IS** pobudził powiązane neurony.





ASSOCIATIVE NEURAL GRAPH ANAKG-2

Neuron **VERY** pobudza połączone z nim neurony.

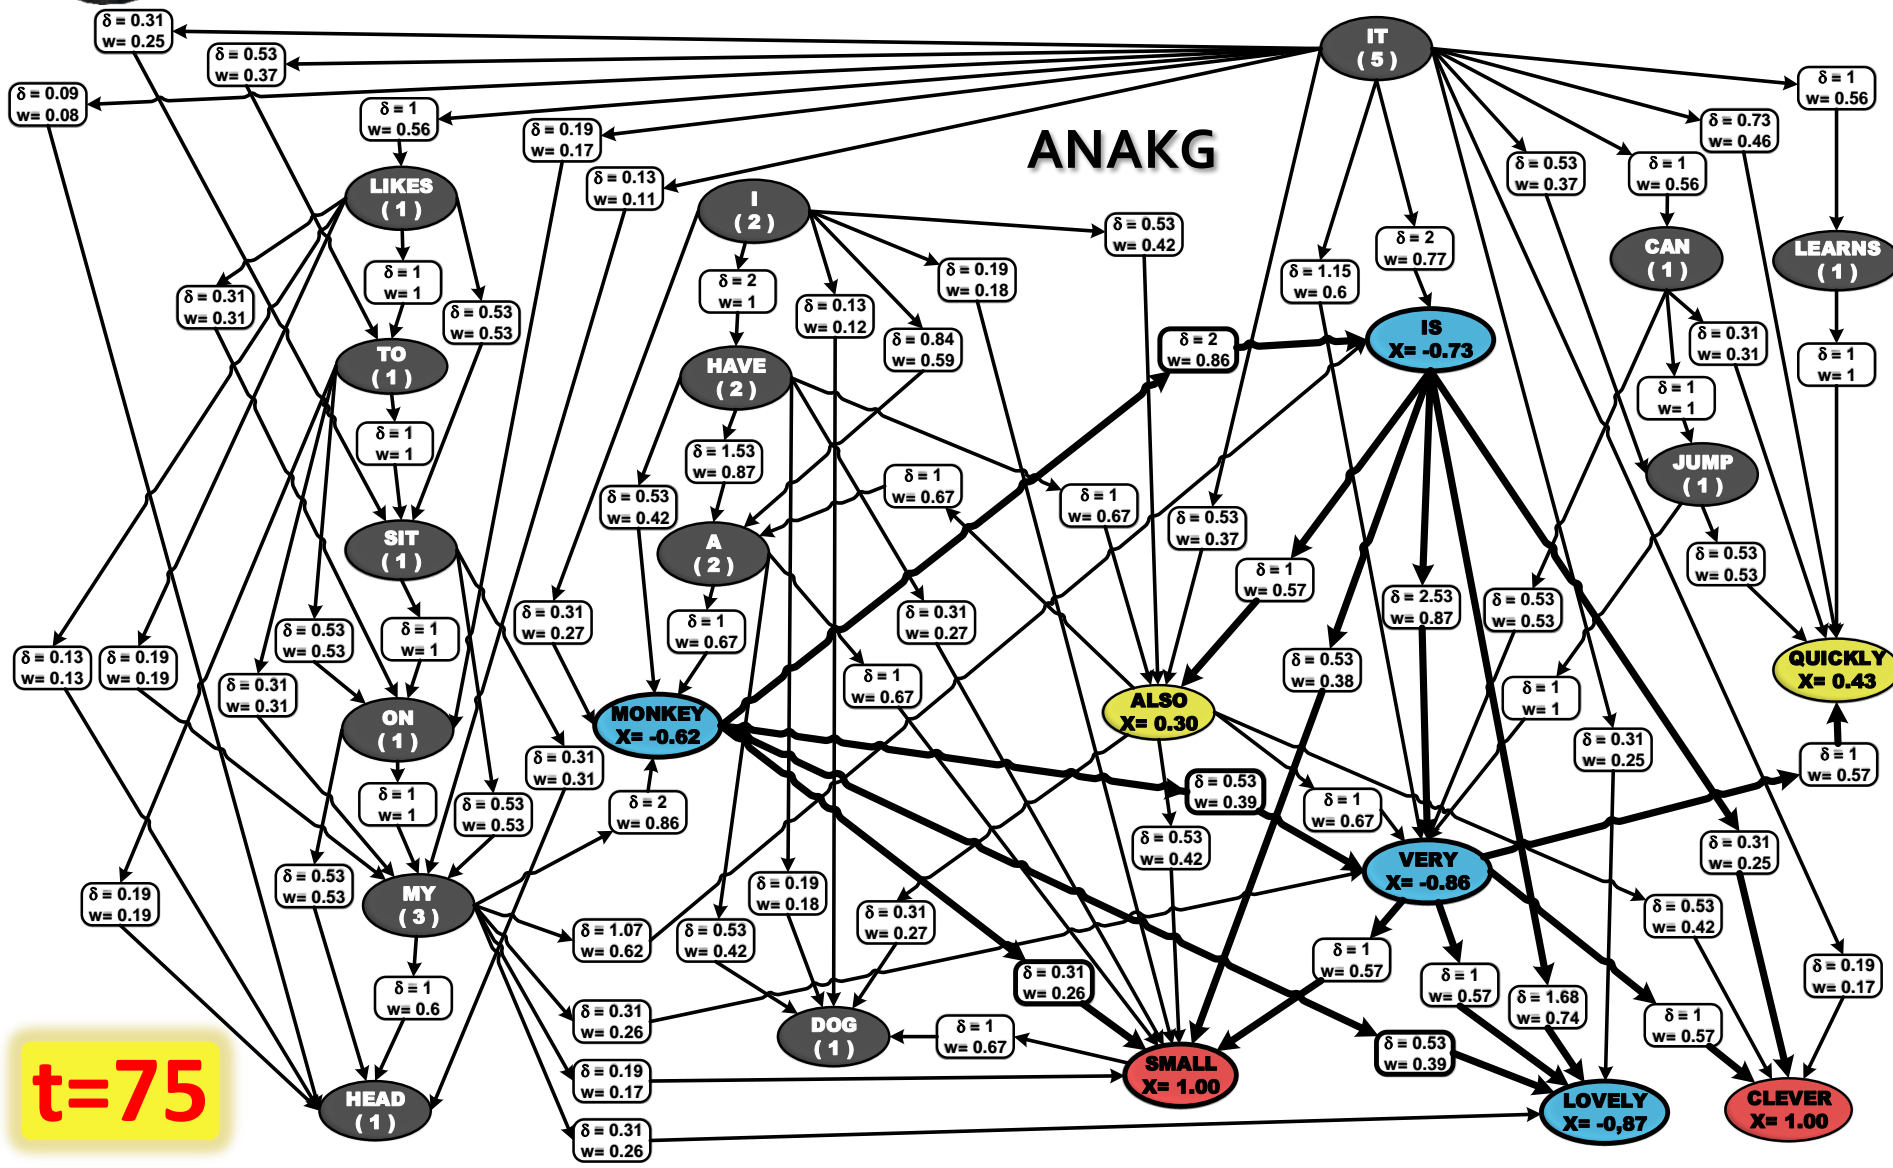


t=61



ASSOCIATIVE NEURAL GRAPH ANAKG-2

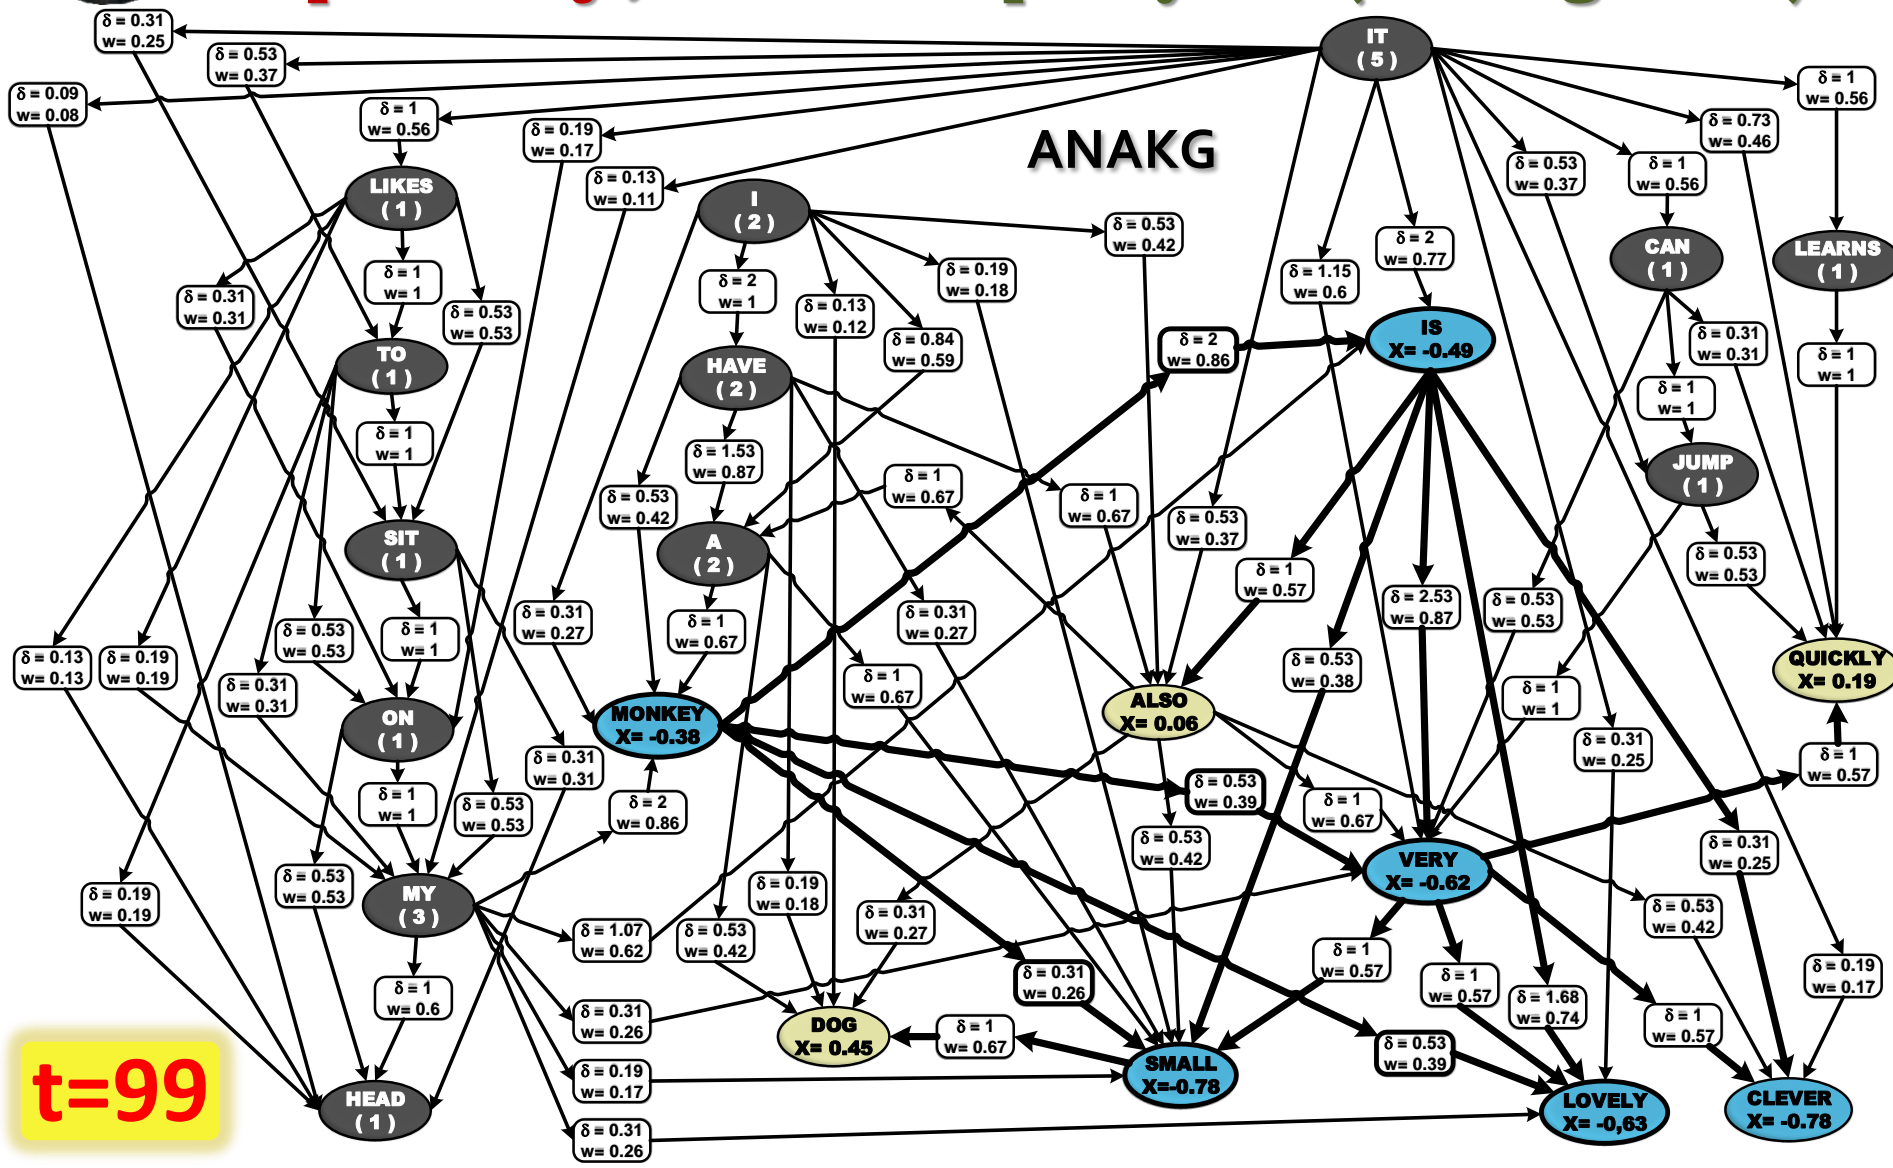
Neurony **SMALL** i **CLEVER** zostają aktywowane.



t=75



Pobudzenia nie powodują już kolejnych aktywacji, więc wszystkie neurony stopniowo powracają do stanu spoczynku (resting state).





ASOCJACYJNY GRAF NEURONOWY udzielił więc następującej odpowiedzi:

MONKEY

IS

VERY

LOVELY

SMALL

CLEVER

35

46

59

60

75

76 t

**Całkowicie się z tym
zgadzam!**



**Dzięki wiedzy o małpce uformowanej
w asocjacyjnym grafie neuronowym
możliwe stało się uzyskanie odpowiedzi!**

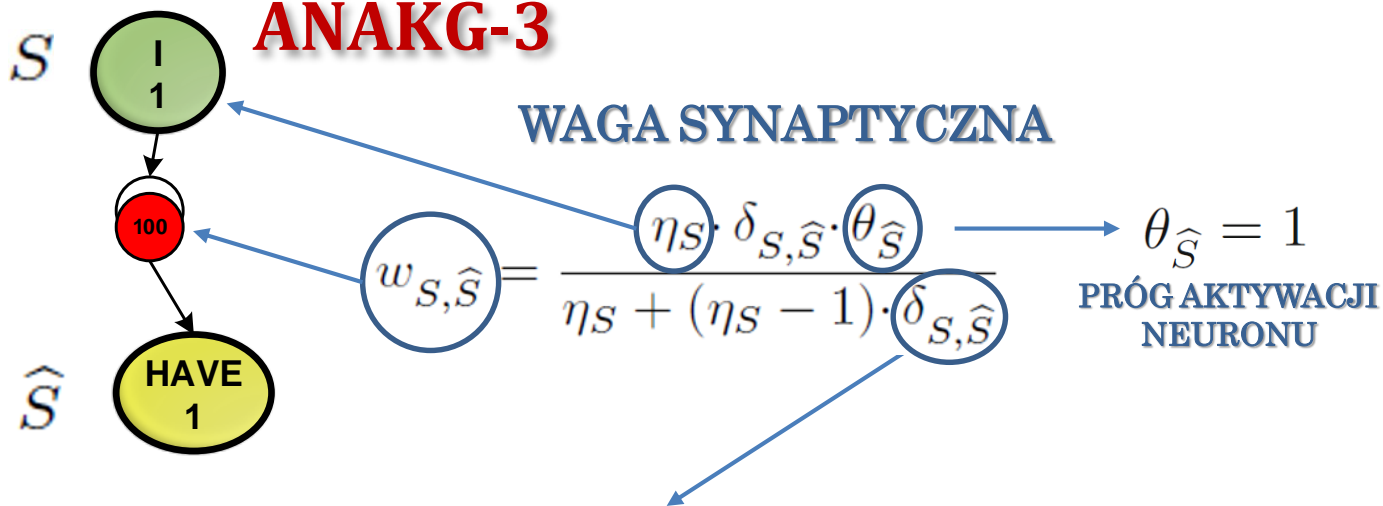


ANAKG-3

S1

S1 I HAVE A MONKEY

ANAKG-3

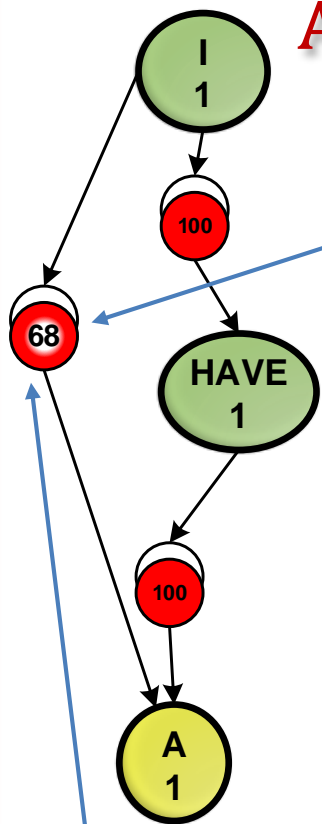


MIARA SKUTECZNOŚCI SYNAPTYCZNEJ

$$\delta_{S,\hat{S}} = \sum_{\{S \rightsquigarrow \hat{S} : (\dots \rightsquigarrow S \rightsquigarrow \dots \rightsquigarrow \hat{S} \rightsquigarrow \dots) \in \mathcal{S}\}} \left(\frac{1}{1 + \frac{\Delta t^{ACT} - \Delta t^{CHARGE}}{\theta_{\hat{S}} \cdot \Delta t^{RECOVER}}} \right)^\gamma$$

ANAKG-3

S1



SYNAPTIC WEIGHT (CONDUCTANCE)

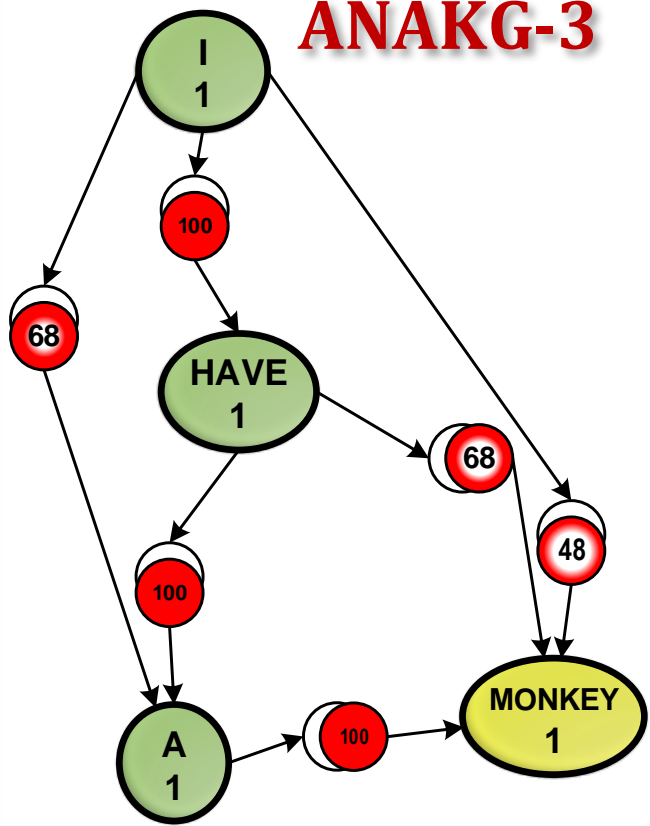
$$w_{S, \hat{S}} = \frac{\eta_S \cdot \delta_{S, \hat{S}} \cdot \theta_{\hat{S}}}{\eta_S + (\eta_S - 1) \cdot \delta_{S, \hat{S}}} = \frac{1 \cdot 0.683 \cdot 1}{1 + (1 - 1) \cdot 0.683} = 0.683$$

SYNAPTIC EFFICIENCY

$$\delta_{S, \hat{S}} = \left(\frac{1}{1 + \frac{\Delta t^{ACT} - \Delta t^{CHARGE}}{\theta_{\hat{S}} \cdot \Delta t^{RECOVER}}} \right)^\gamma = \left(\frac{1}{1 + \frac{5-2}{1 \cdot 30}} \right)^4 = 0.683$$

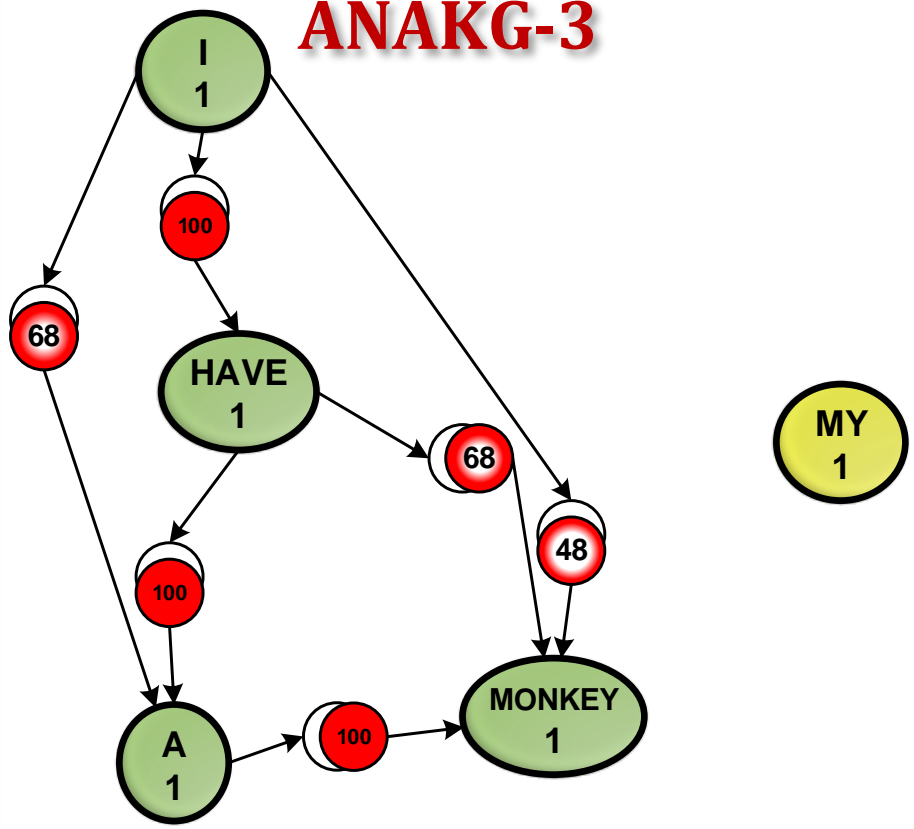
ANAKG-3

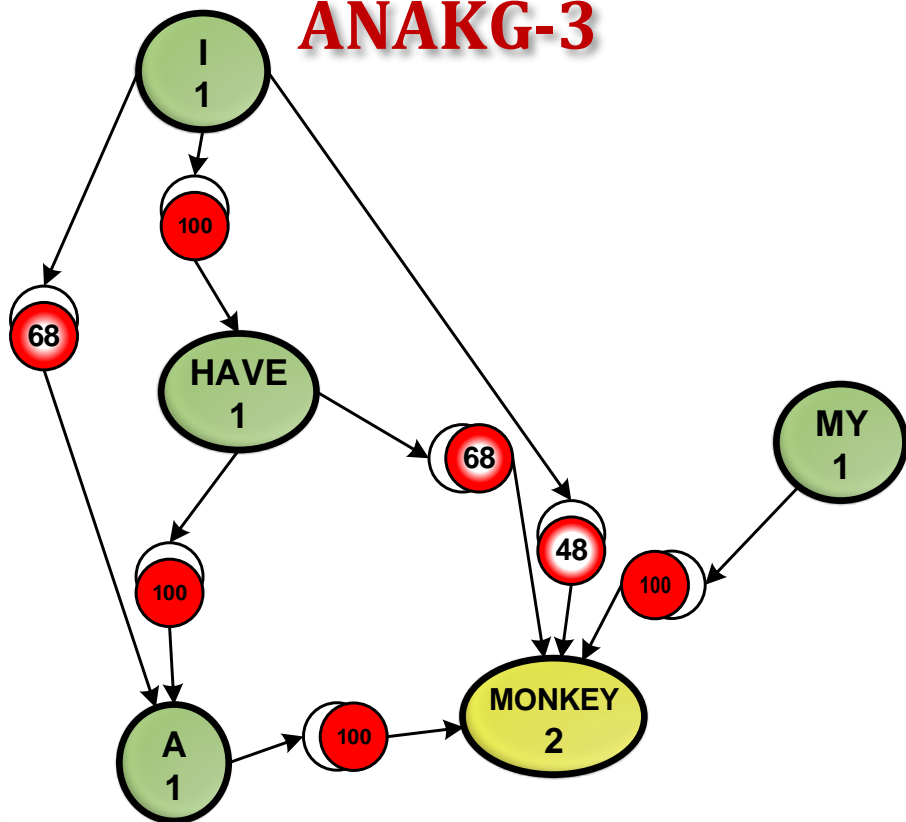
S1



S1 I HAVE A MONKEY

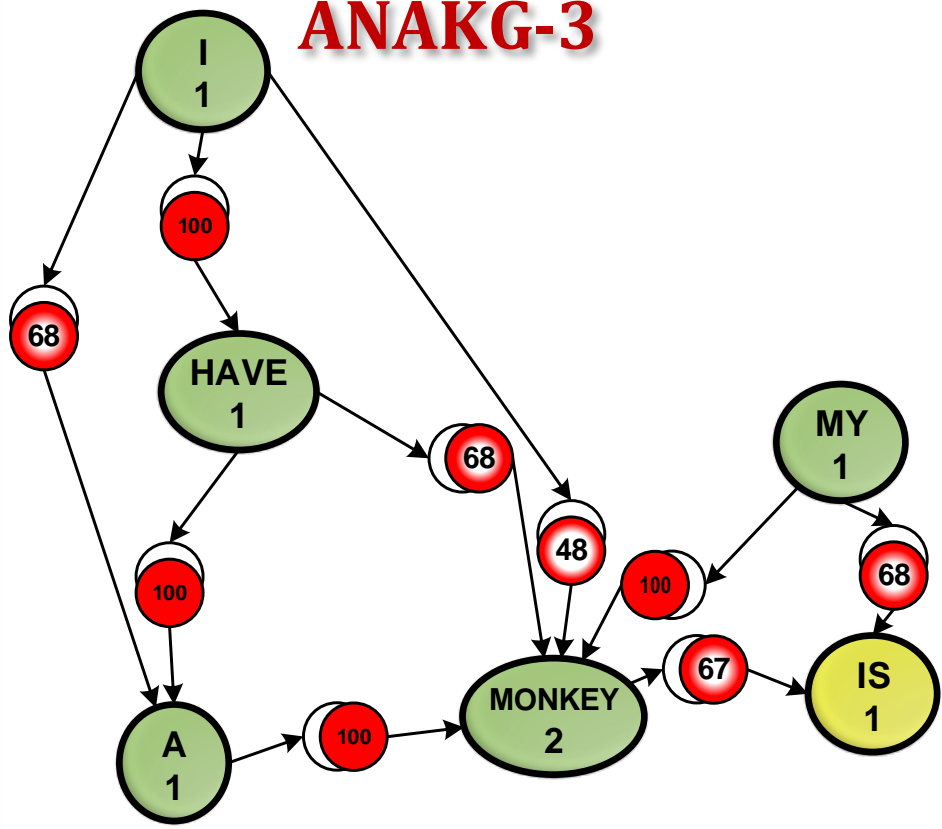
ANAKG-3





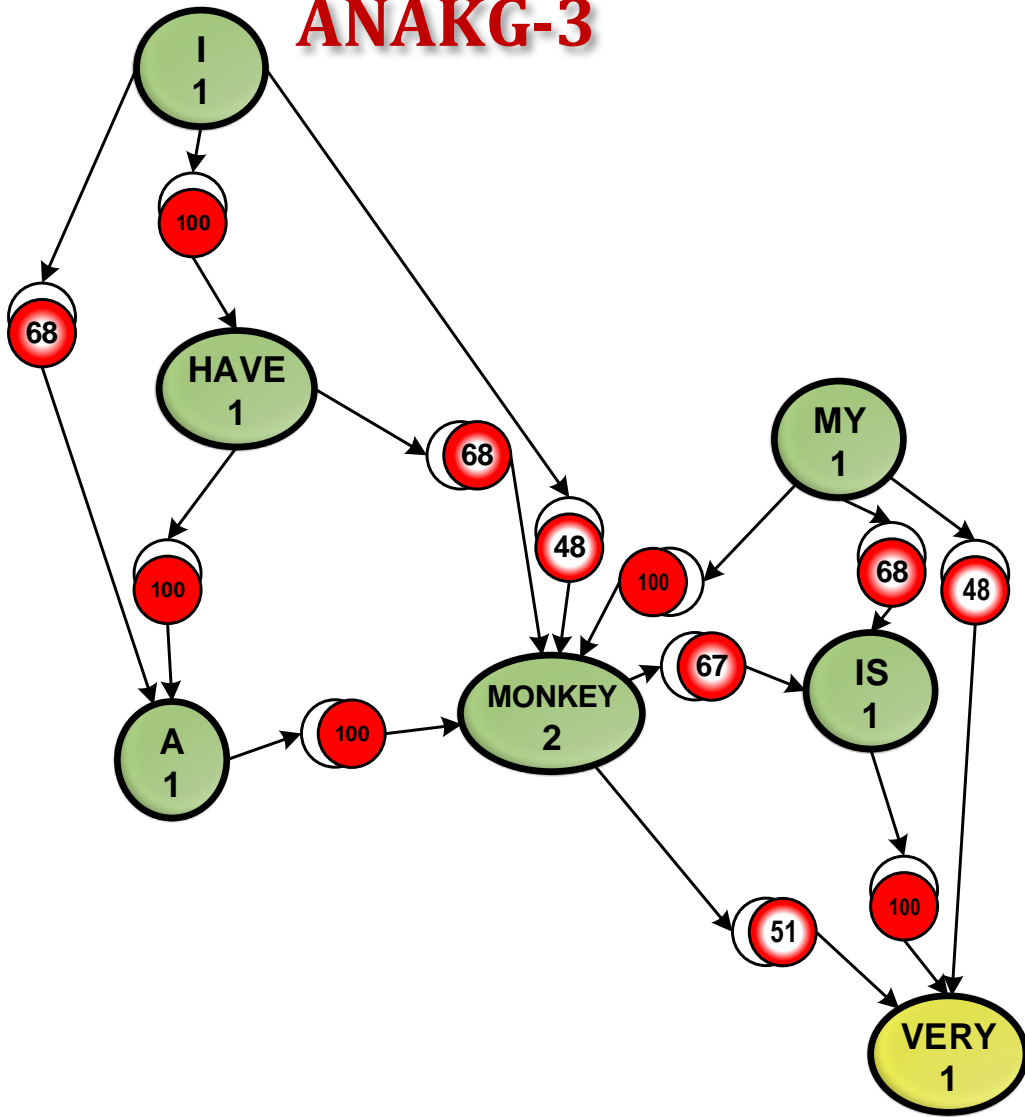
NEURONOWA AGREGACJA REPREZENTACJI OBIEKTÓW

ANAKG-3



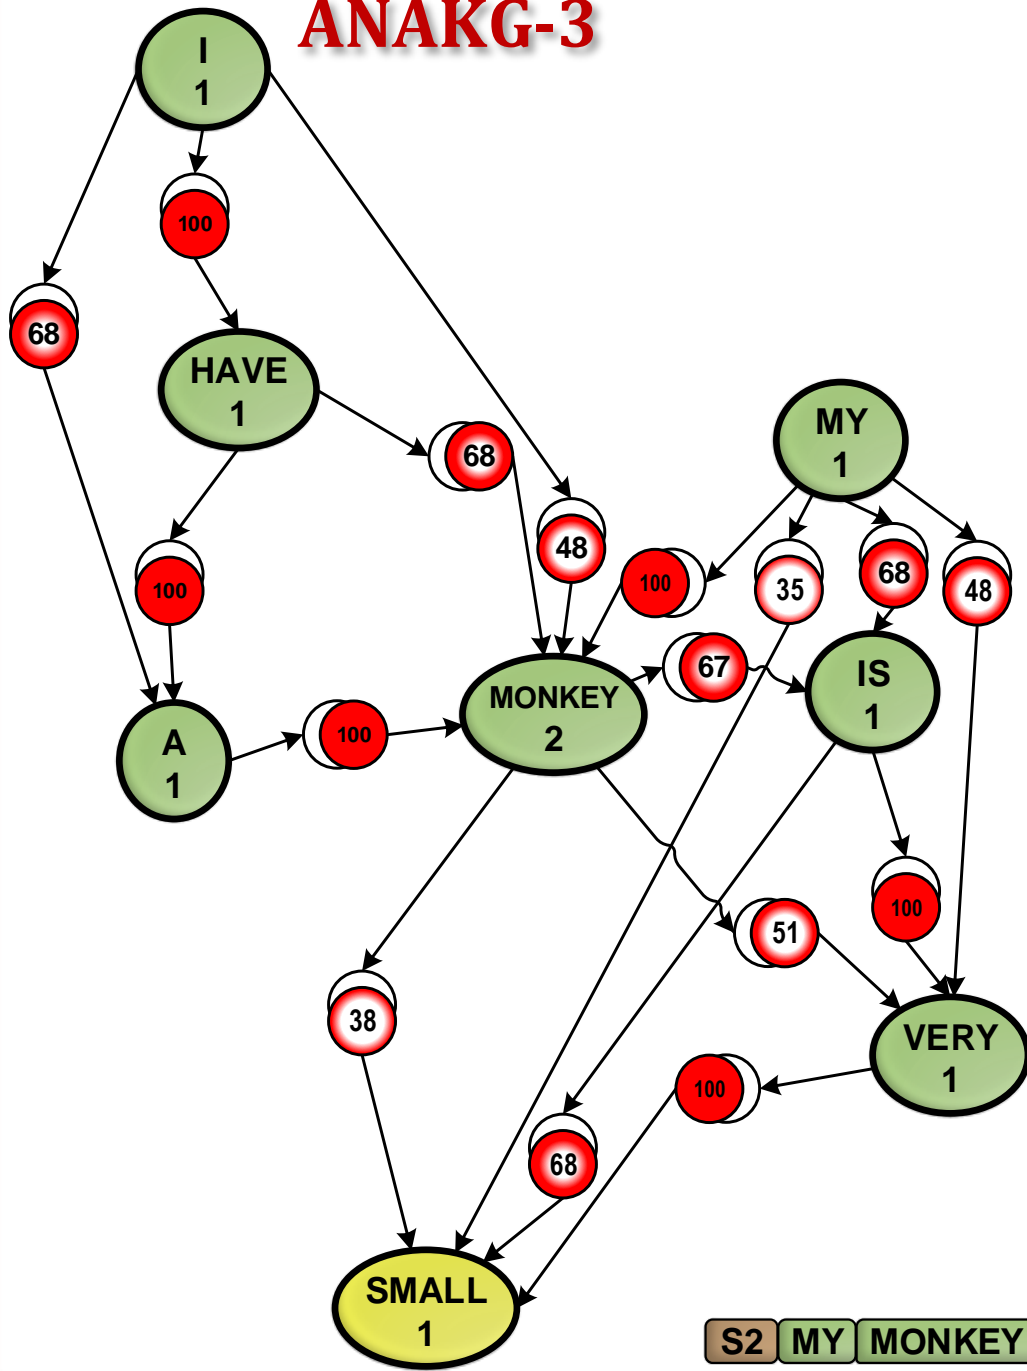
ANAKG-3

S2

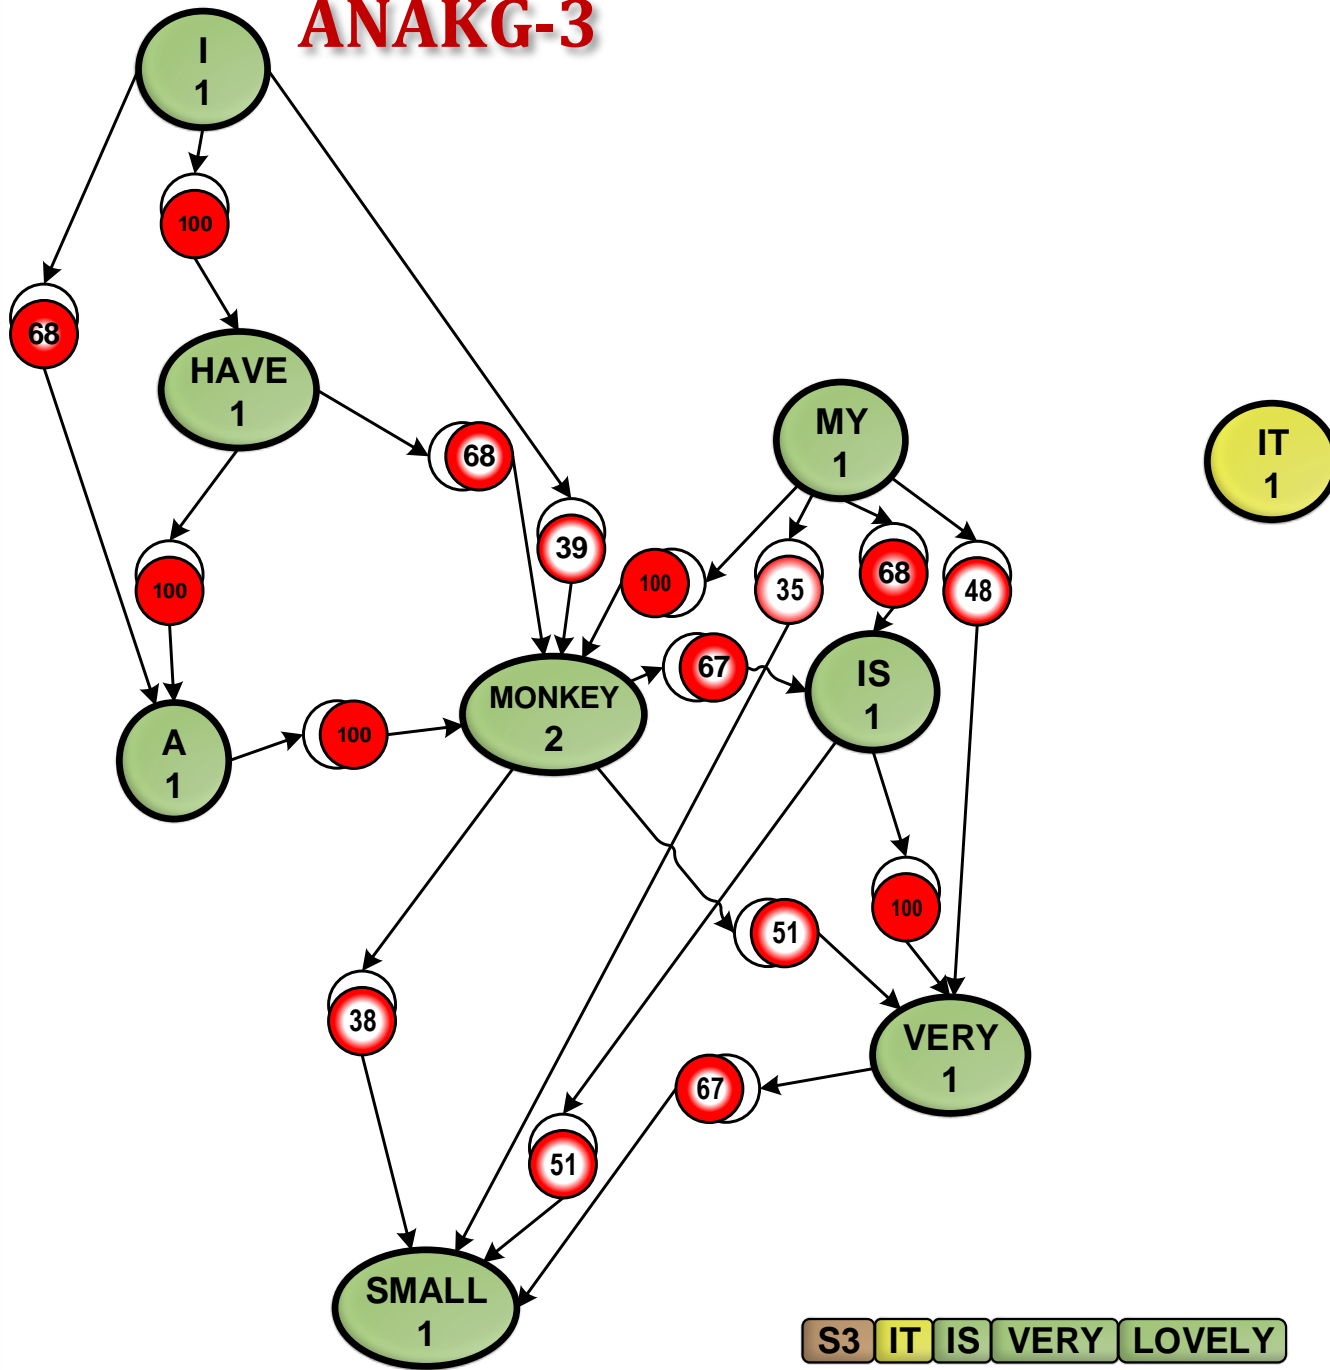


S2 MY MONKEY IS VERY SMALL

ANAKG-3



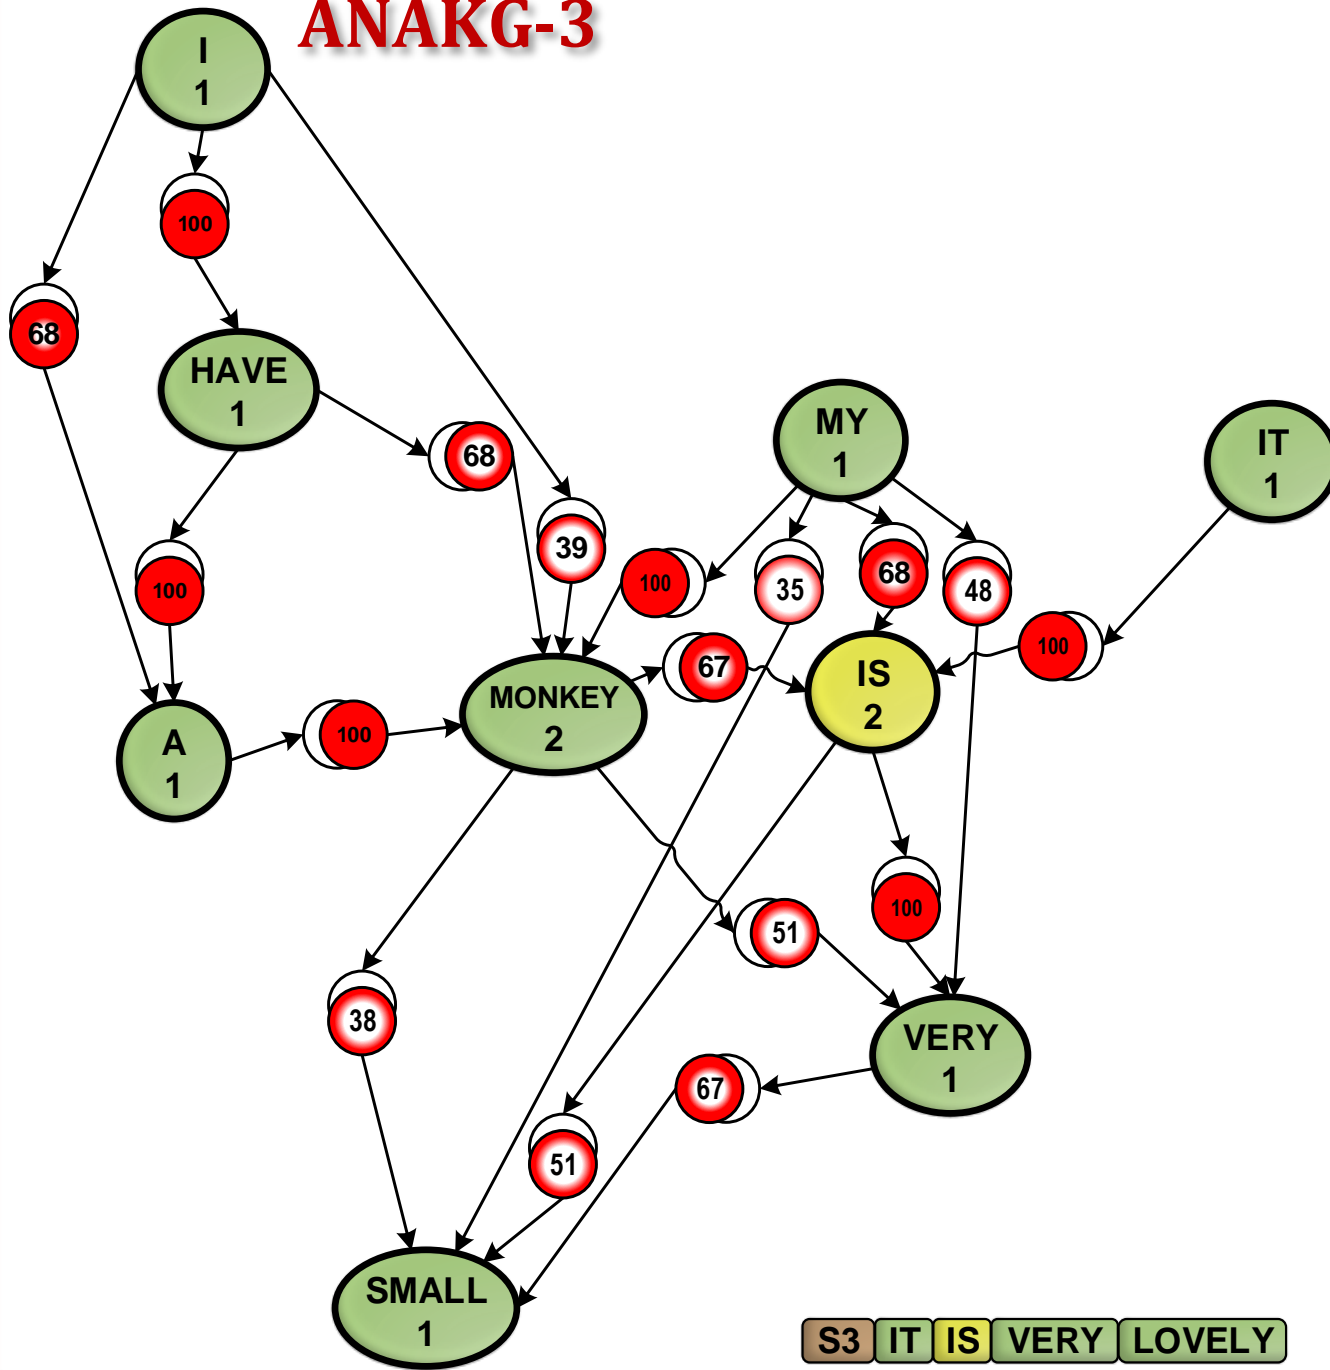
ANAKG-3



S3 IT IS VERY LOVELY

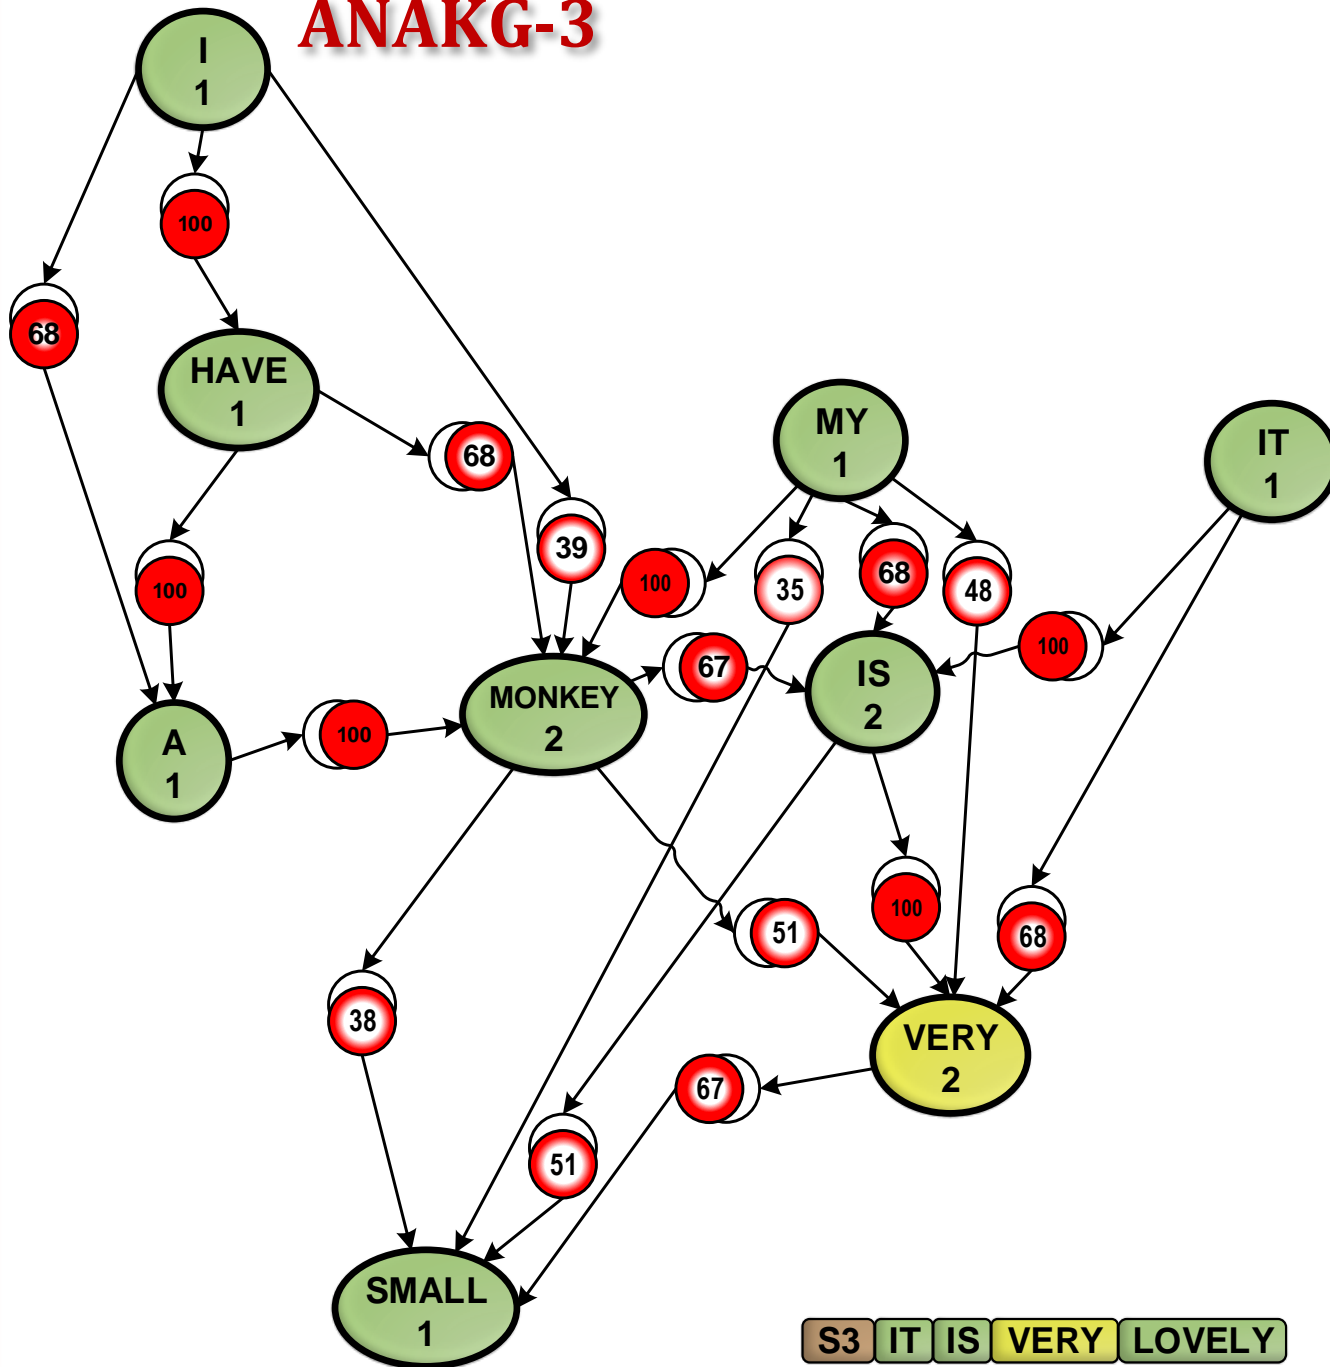
ANAKG-3

S3



S3 IT IS VERY LOVELY

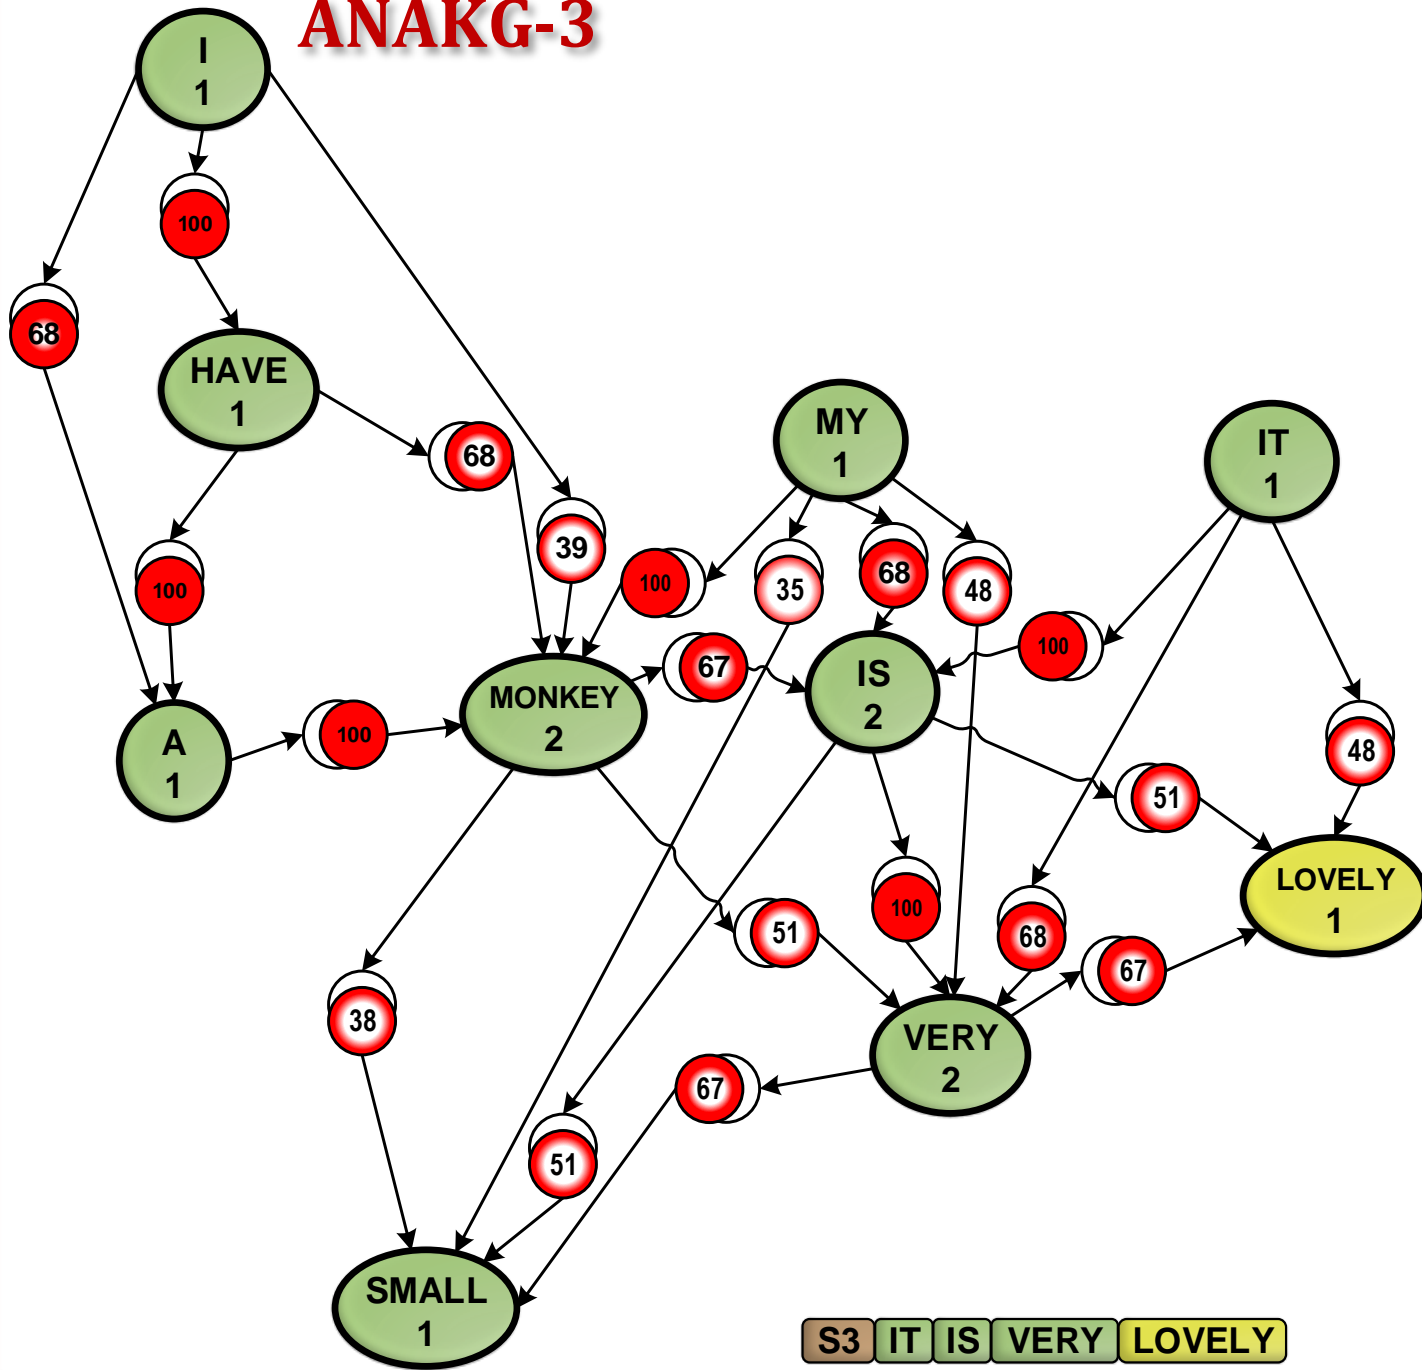
ANAKG-3



S3 IT IS VERY LOVELY

ANAKG-3

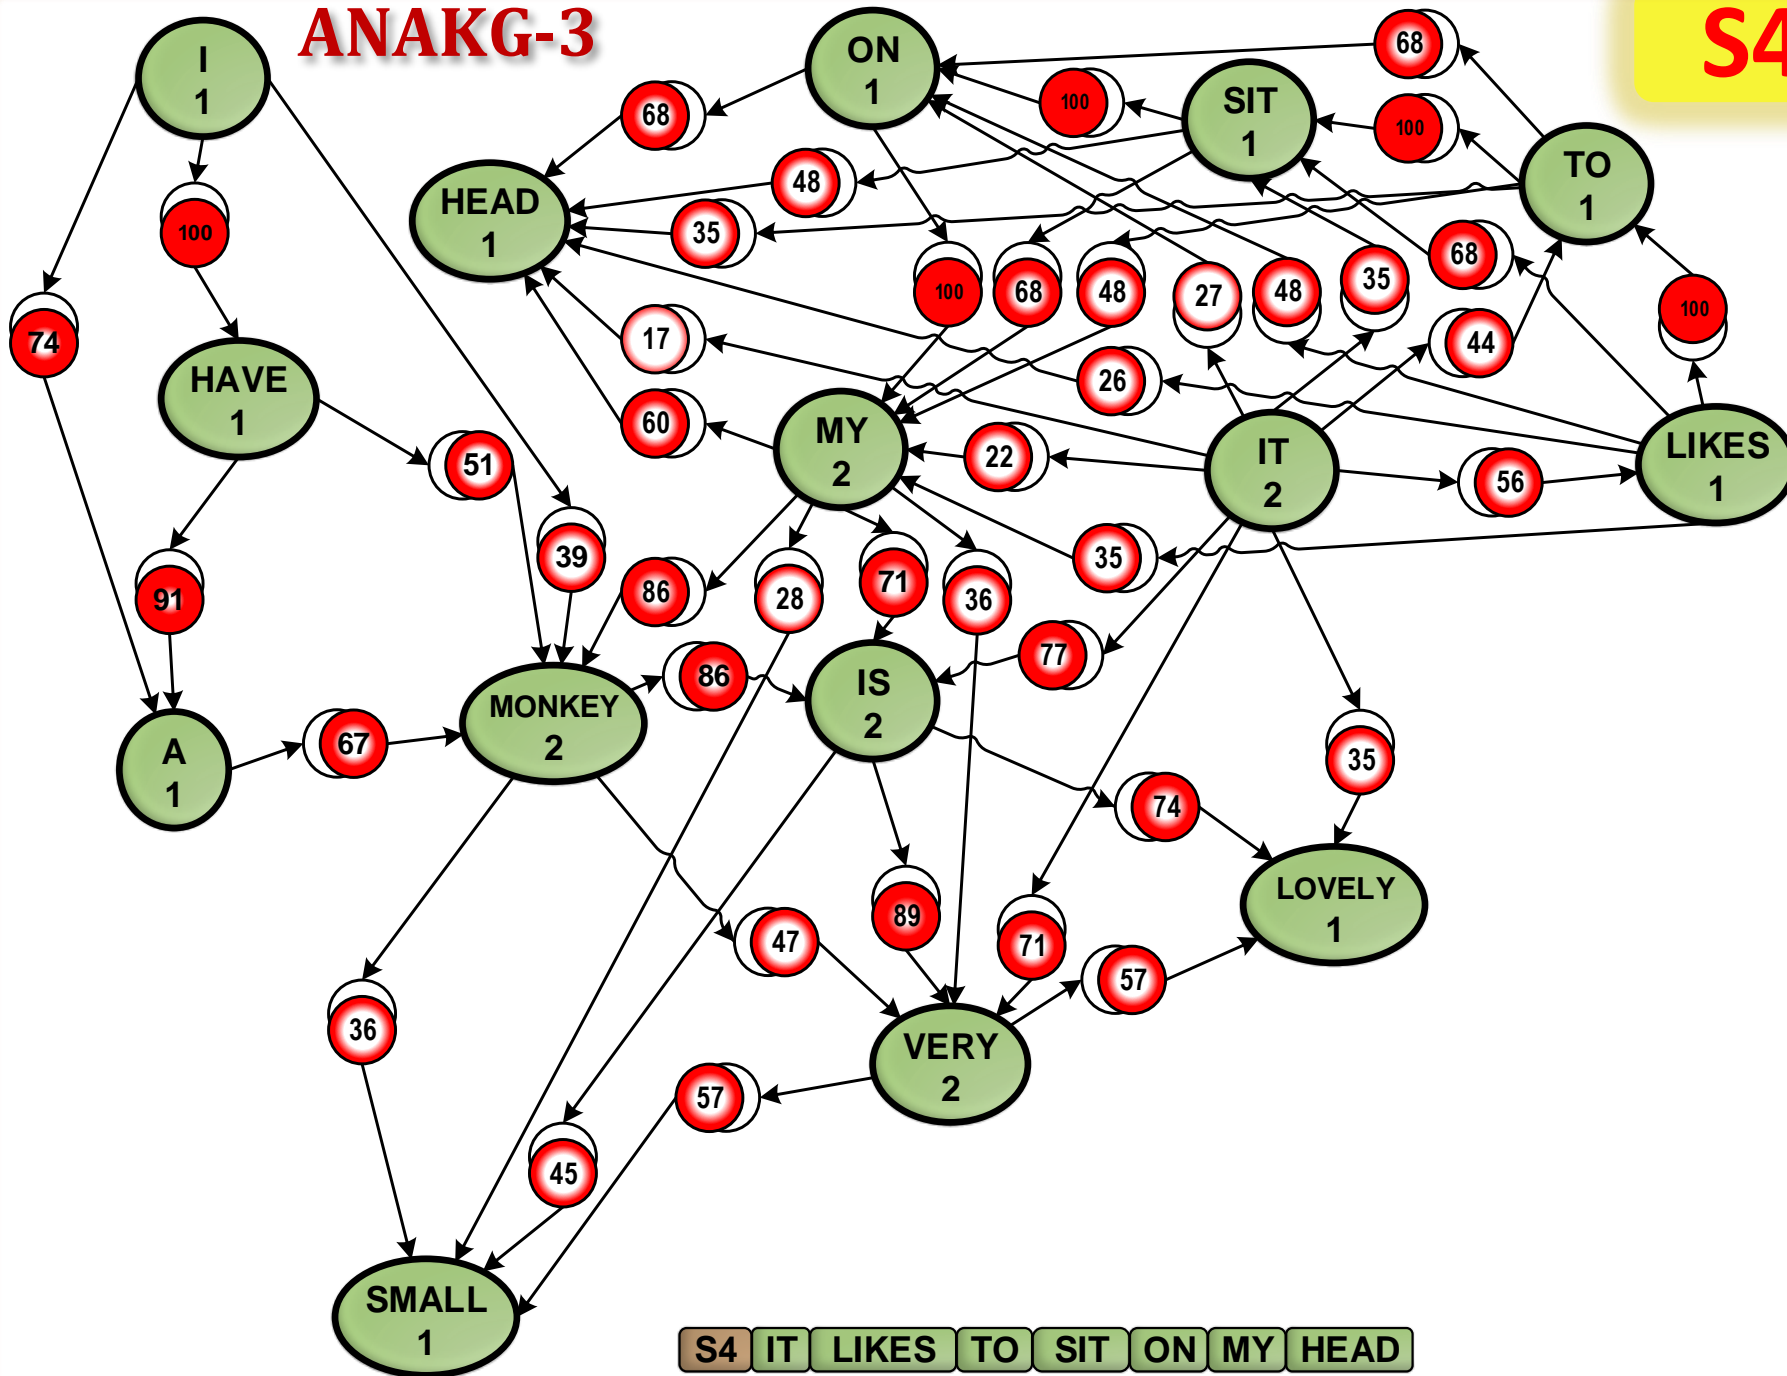
S3



S3 IT IS VERY LOVELY

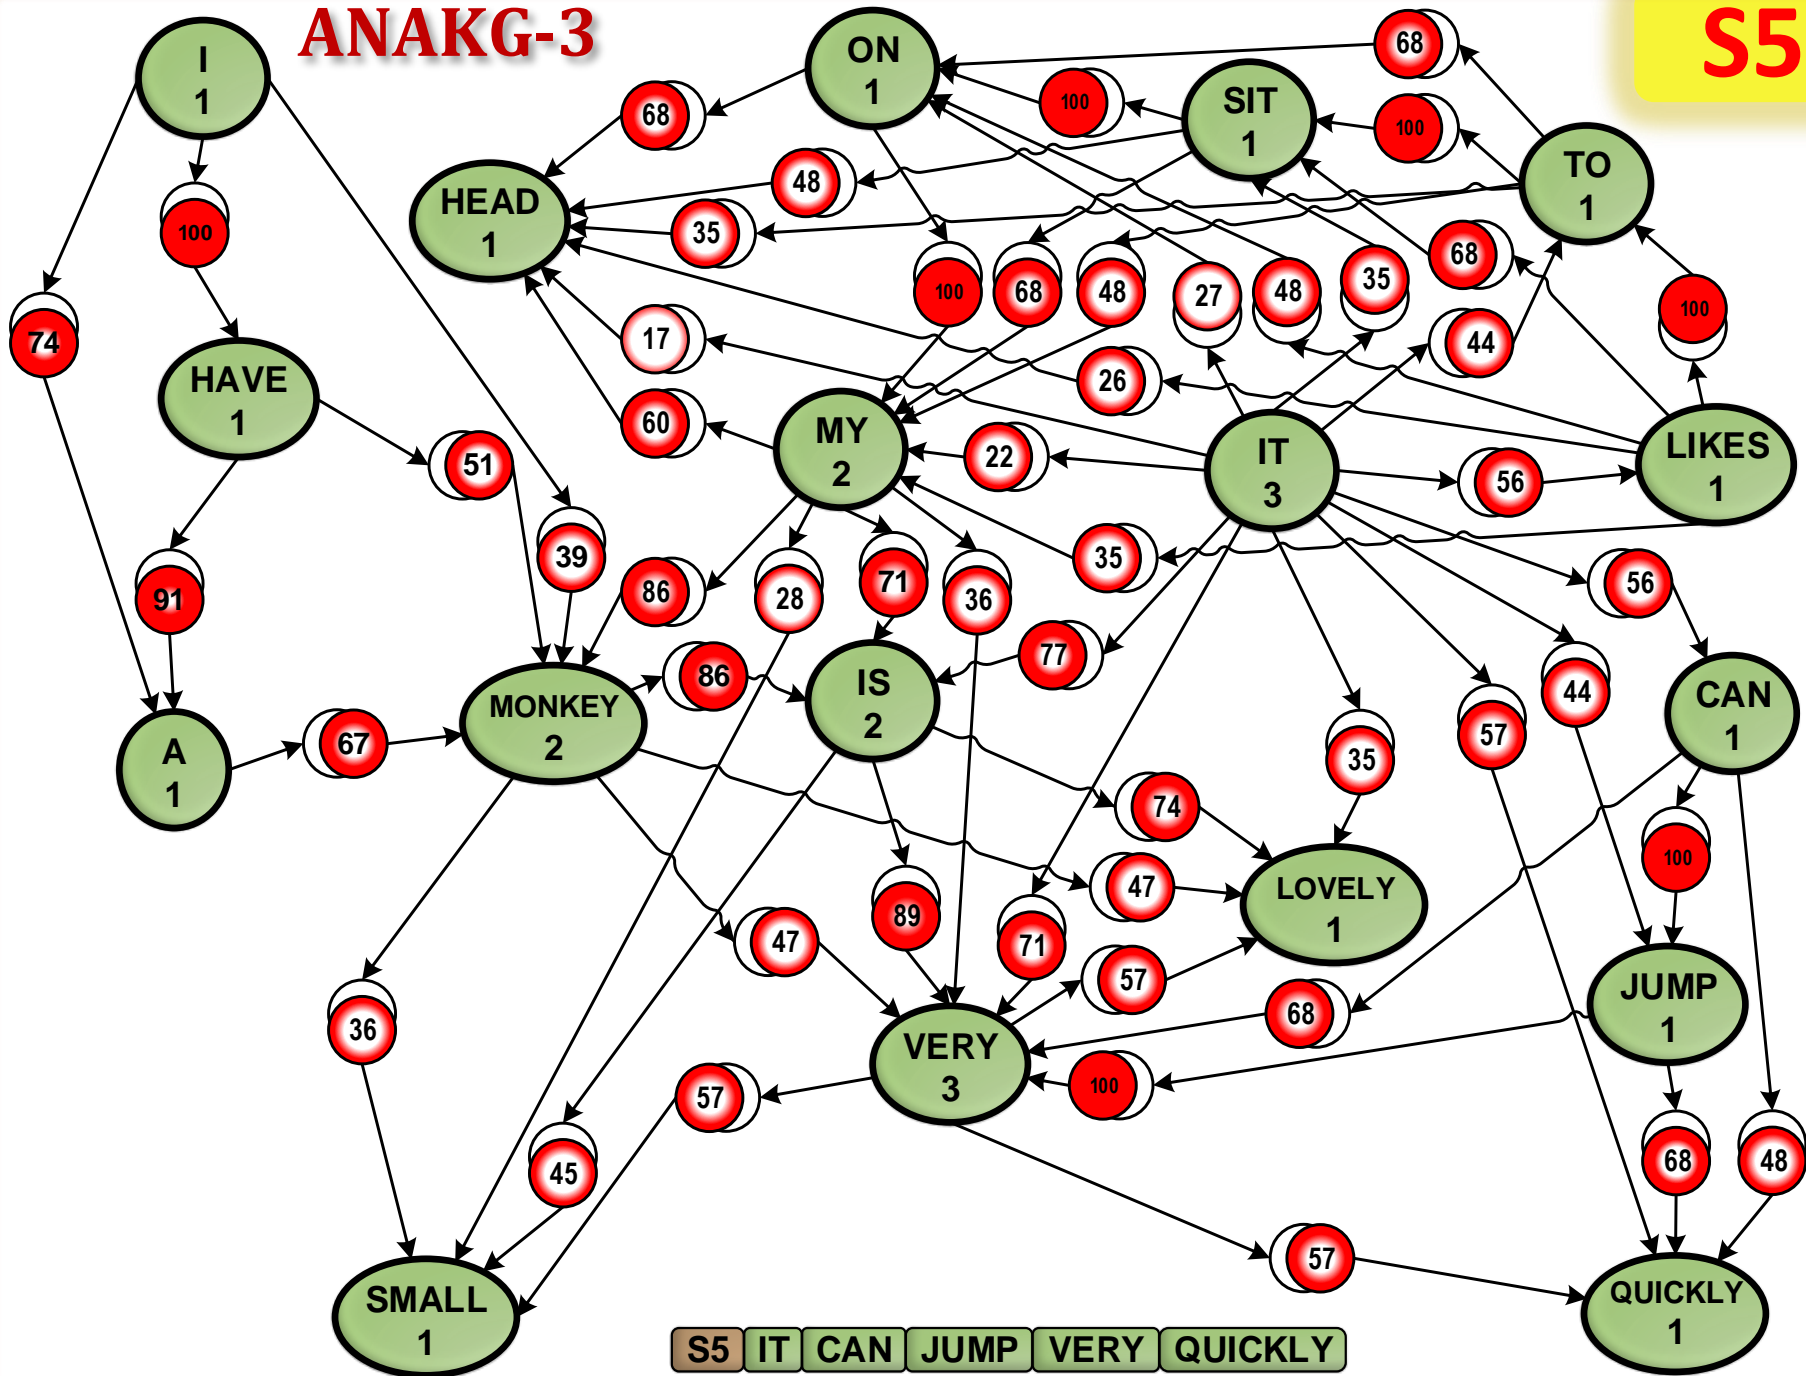
ANAKG-3

S4



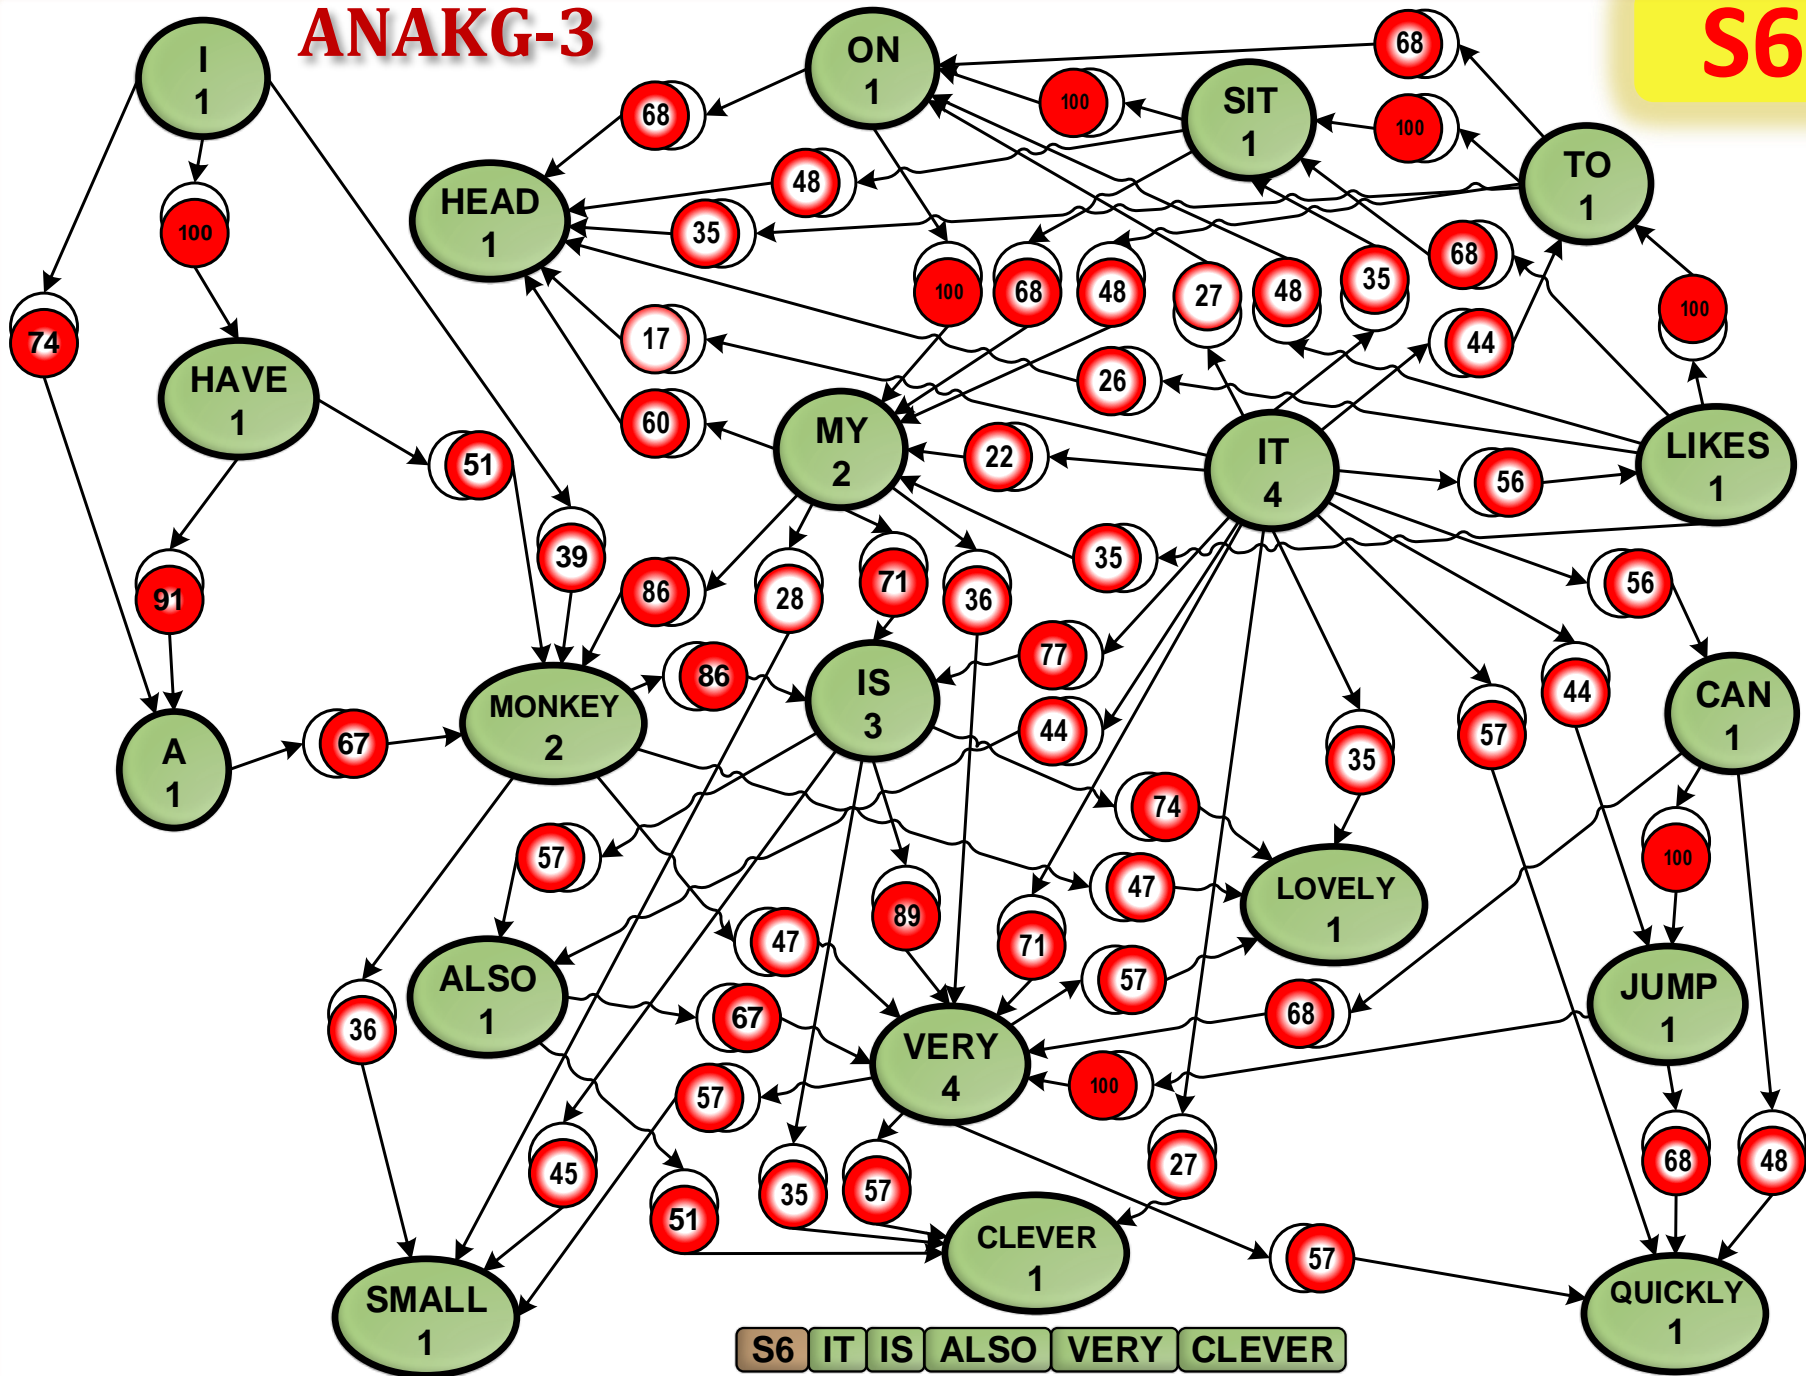
ANAKG-3

S5



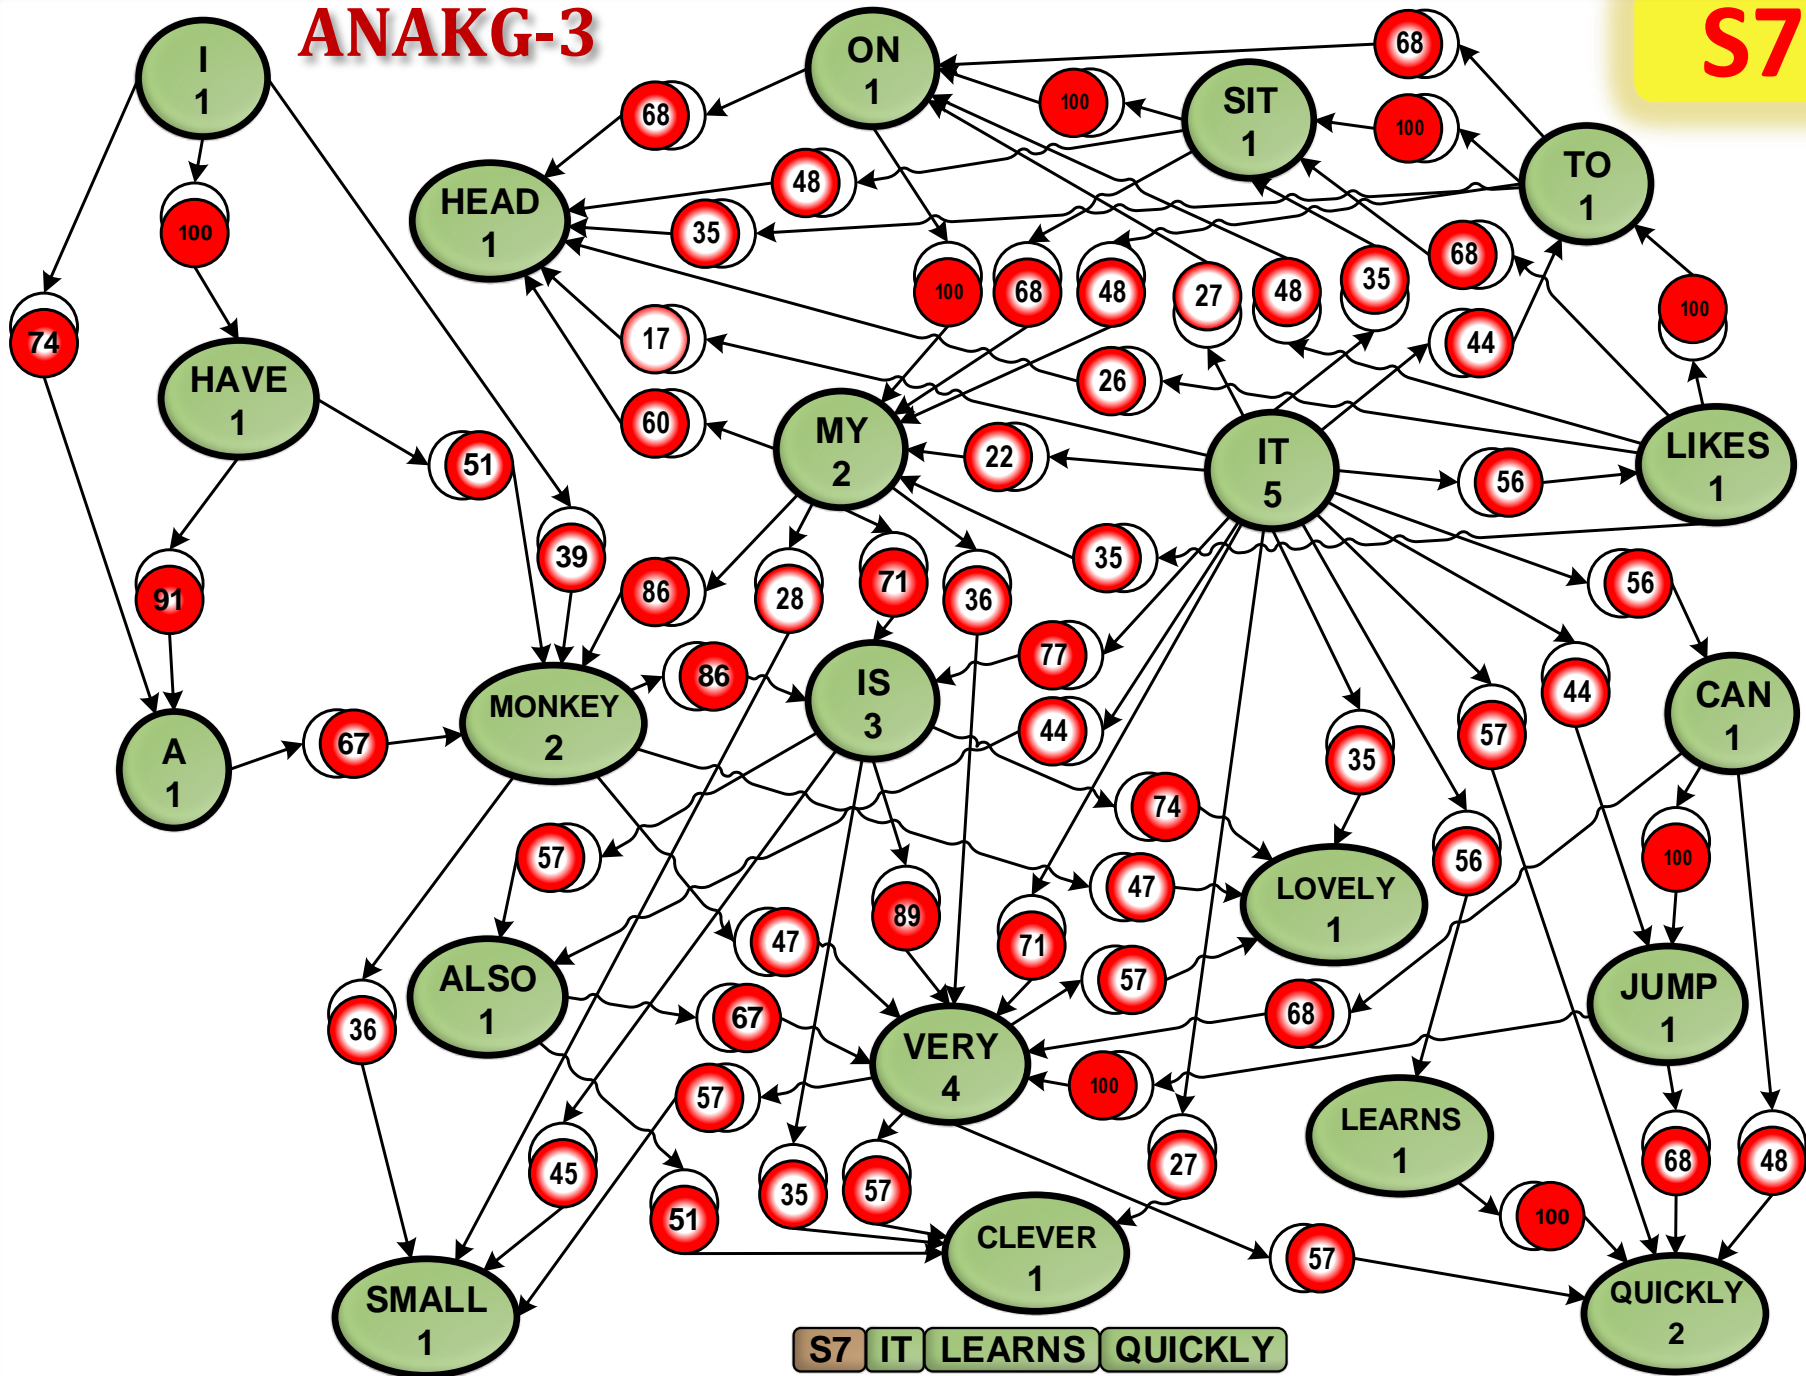
ANAKG-3

S6



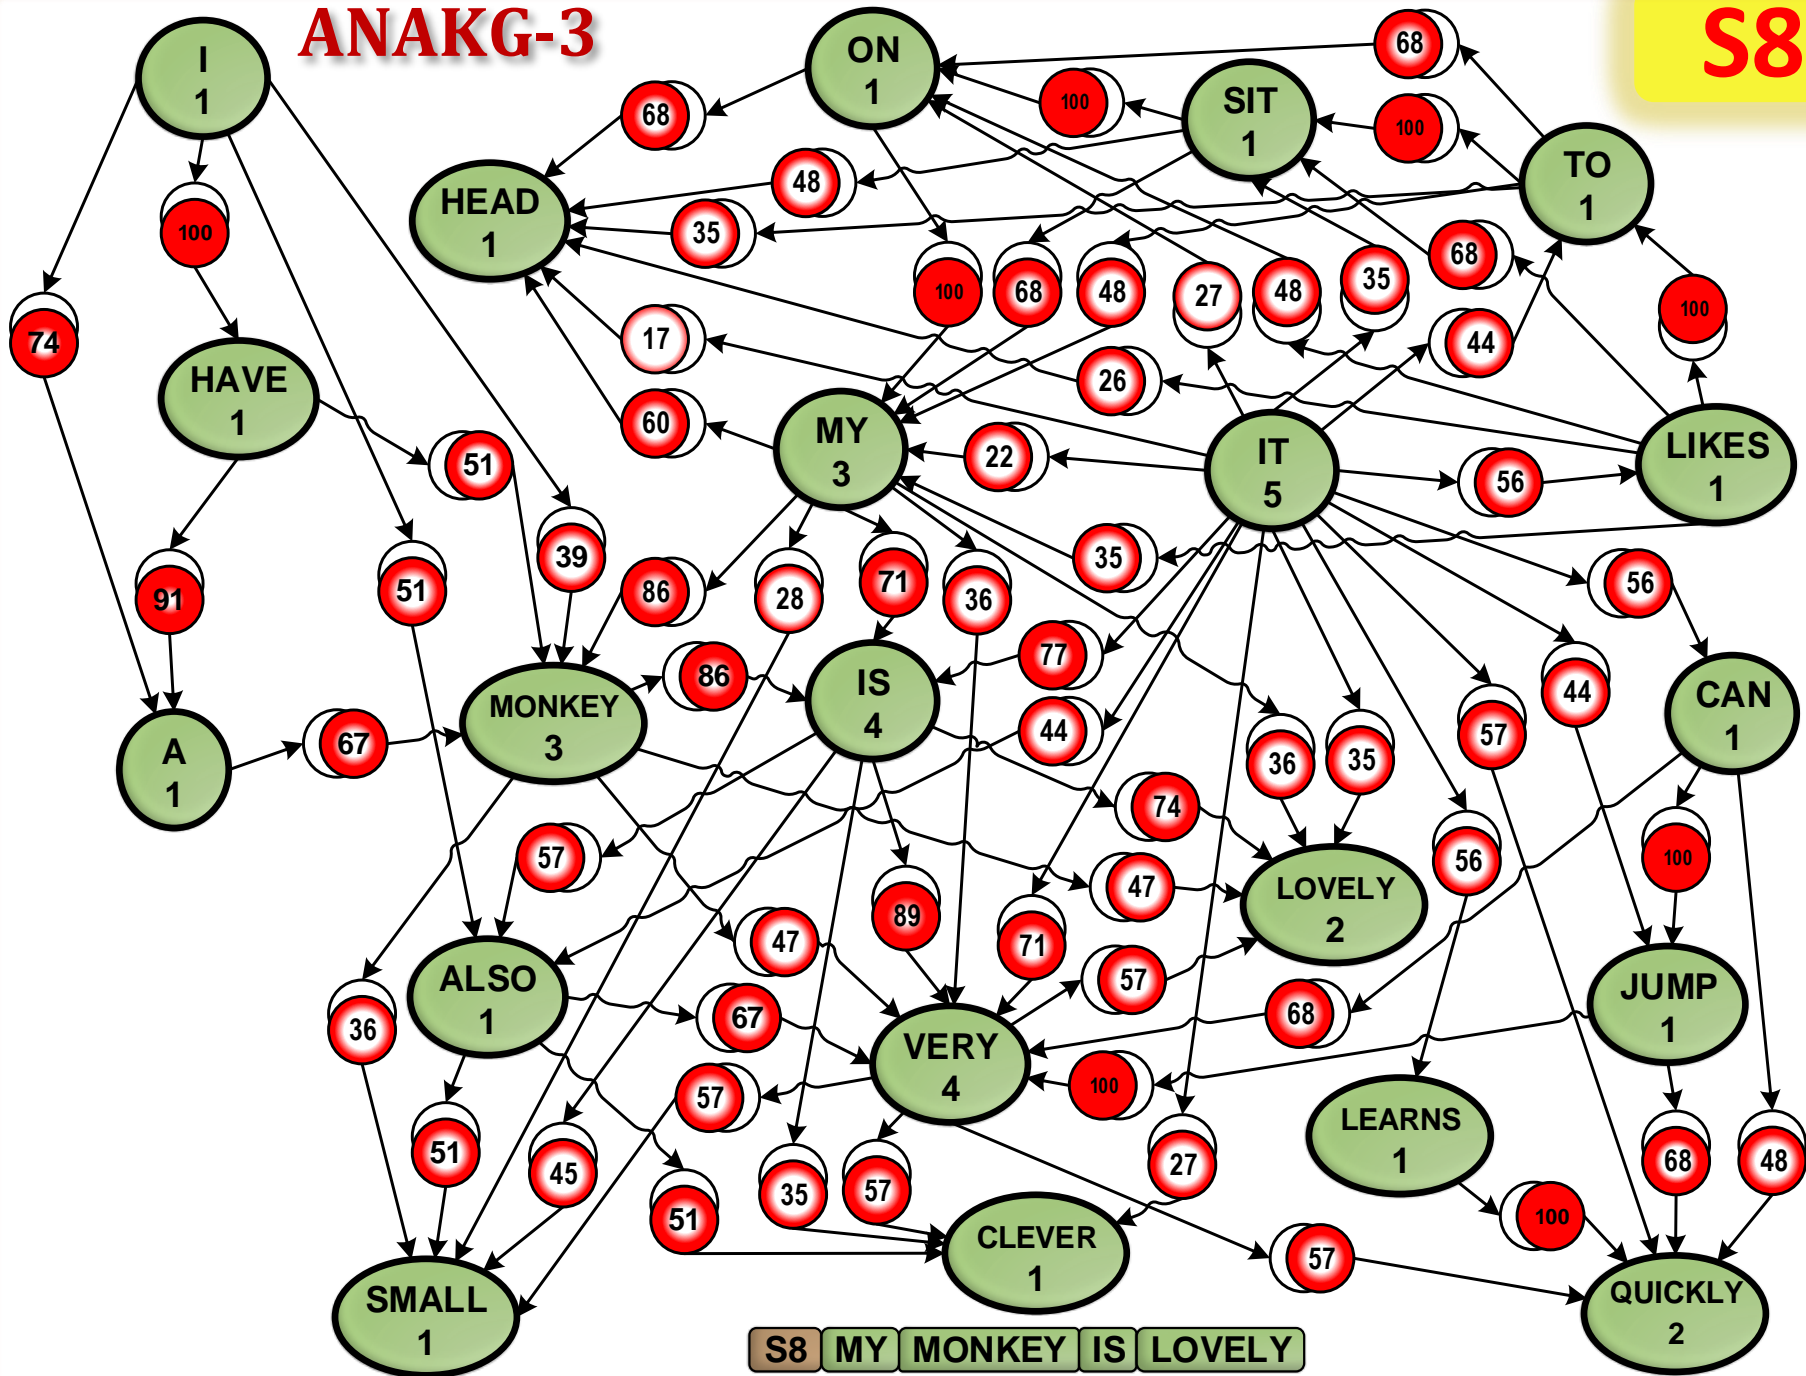
ANAKG-3

S7



ANAKG-3

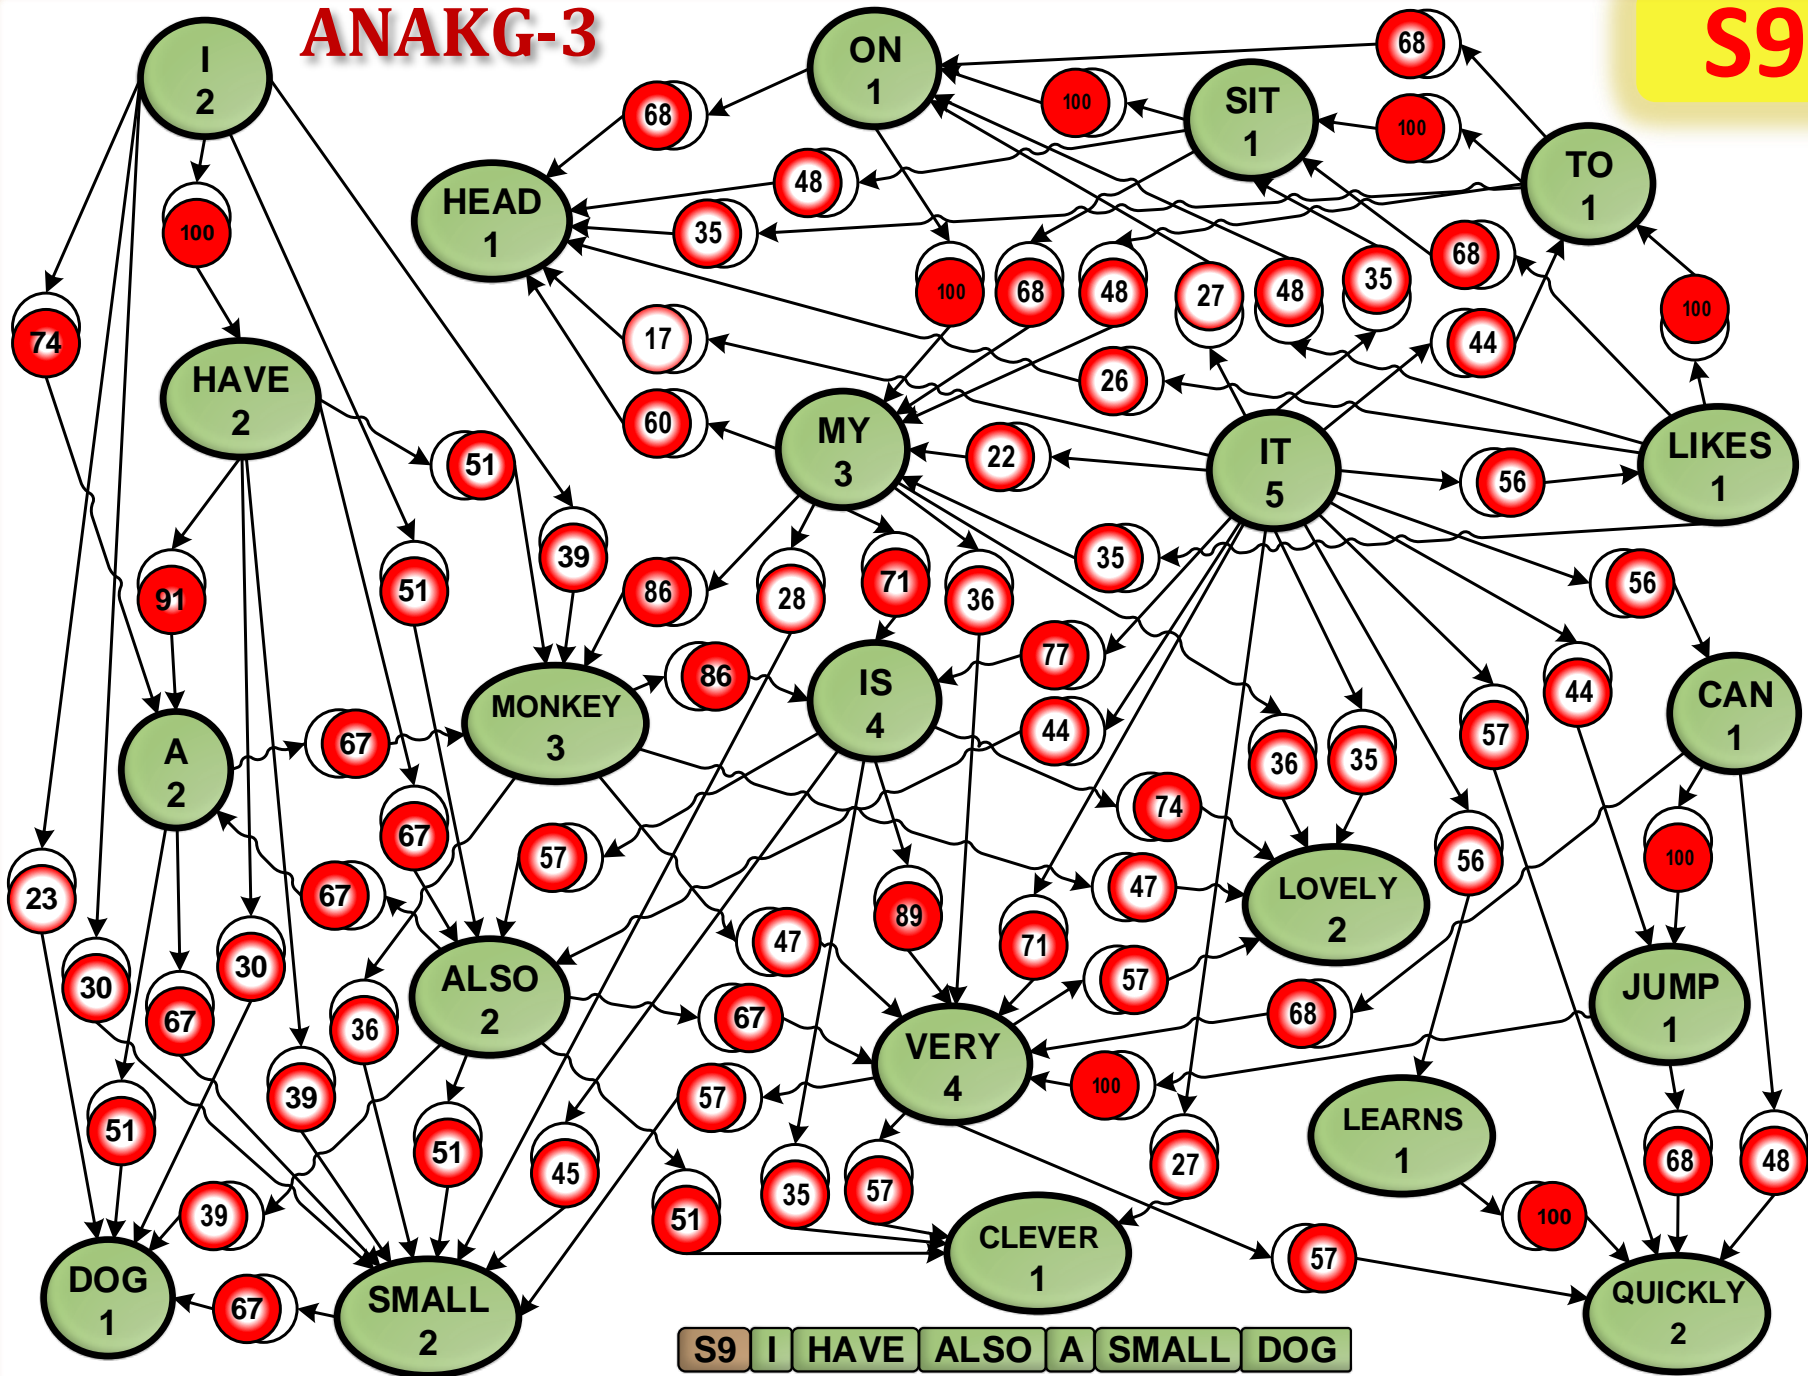
S8



S8 MY MONKEY IS LOVELY

ANAKG-3

S9



OBLICZANIE SKUTECZNOŚCI SYNAPTYCZNEJ



$$\delta_{S, \hat{S}} = \sum_{\{S \rightsquigarrow \hat{S} : (\dots \rightsquigarrow S \rightsquigarrow \dots \rightsquigarrow \hat{S} \rightsquigarrow \dots) \in \mathcal{S}\}} \left(\frac{1}{1 + \frac{\Delta t^{ACT} - \Delta t^{CHARGE}}{\theta_{\hat{S}} \cdot \Delta t^{RECOVER}}} \right)^\gamma$$

		POSTSYNAPTIC AS-NEURON																						
	$\Sigma \delta$	A	ALSO	CAN	CLEVER	DOG	HAVE	HEAD	I	IS	IT	JUMP	LEARNS	LIKES	LOVELY	MONKEY	MY	ON	QUICKLY	SIT	SMALL	TO	VERY	
PRESYNAPTIC AS-NEURON	2	A				0,683										1,000					1,000			
	2	ALSO	1,000			0,683	0,482															0,683		1,000
	1	CAN										1,000								0,482				0,683
	1	CLEVER																						
	1	DOG																						
	2	HAVE	1,683	1,000			0,350										0,683						0,482	
	1	HEAD																						
	2	I	1,165	0,683			0,260	2,000									0,482						0,350	
	4	IS		1,000		0,482										1,683						0,683		2,683
	5	IT		0,683	1,000	0,350			0,198		2,000		0,683	1,000	1,000	0,482		0,260	0,350	1,033	0,482		0,683	1,647
	1	JUMP																		0,683				1,000
	1	LEARNS																		1,000				
	1	LIKES							0,260									0,350	0,482		0,683		1,000	
	2	LOVELY																						
	3	MONKEY									2,000					0,683						0,482		0,683
	3	MY							1,000	1,366						0,482	2,000					0,350		0,482
	1	ON							0,683									1,000						
	2	QUICKLY																						
	1	SIT							0,482									0,683	1,000					
	2	SMALL					1,000																	
	1	TO							0,350									0,482	0,683		1,000			
	4	VERY				1,000										1,000				1,000		1,000		

OBLICZANIE WAG SYNAPTYCZNYCH



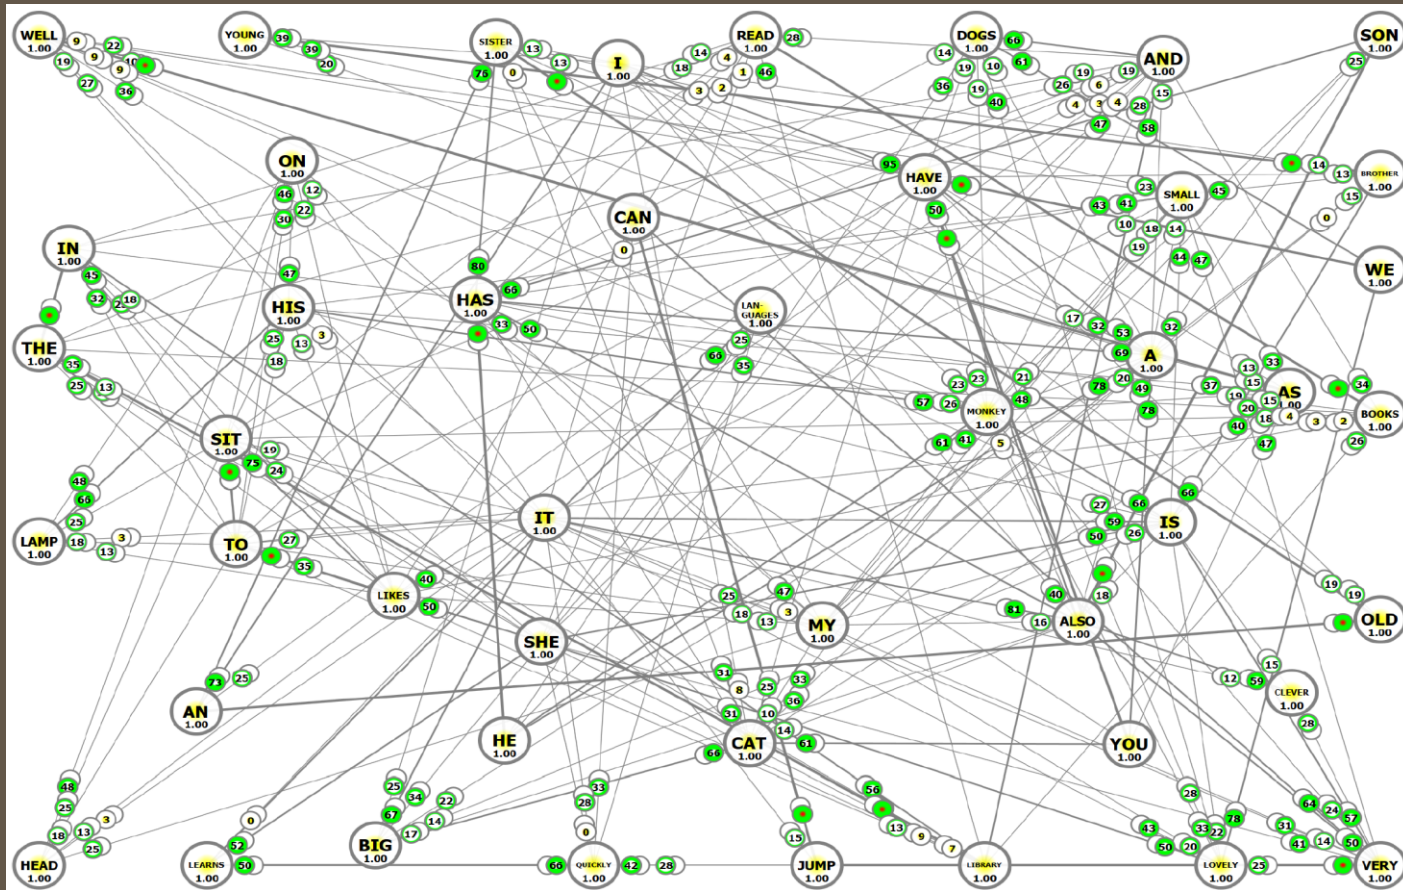
$$w_{S,\hat{S}} = \frac{\eta_S \cdot \delta_{S,\hat{S}} \cdot \theta_{\hat{S}}}{\eta_S + (\eta_S - 1) \cdot \delta_{S,\hat{S}}}$$

ANAKG-3

		POSTSYNAPTIC AS-NEURON																						
PRESYNAPTIC AS-NEURON	w	A	ALSO	CAN	CLEVER	DOG	HAVE	HEAD	I	IS	IT	JUMP	LEARNS	LIKES	LOVELY	MONKEY	MY	ON	QUICKLY	SIT	SMALL	TO	VERY	
	A					0,509										0,667						0,667		
	ALSO	0,667			0,509	0,388																0,509		0,667
	CAN											1,000								0,482				0,683
	CLEVER																							
	DOG																							
	HAVE	0,914	0,667			0,298										0,509							0,388	
	HEAD																							
	I	0,736	0,509			0,230	1,000									0,388							0,298	
	IS		0,571		0,354											0,744						0,452		0,891
	IT		0,442	0,556	0,273			0,171		0,769		0,442	0,556	0,556	0,348			0,215	0,273	0,566	0,348		0,442	0,711
	JUMP																				0,683			1,000
	LEARNS																			1,000				
	LIKES							0,260										0,350	0,482		0,683		1,000	
	LOVELY																							
	MONKEY									0,857						0,469							0,365	0,469
	MY							0,600		0,715						0,365	0,857					0,284		0,365
	ON							0,683										1,000						
	QUICKLY																							
	SIT							0,482										0,683	1,000					
	SMALL					0,667																		
	TO							0,350										0,482	0,683		1,000			
	VERY				0,571											0,571				0,571		0,571		



ACTIVE NEURO-ASSOCIATIVE KNOWLEDGE GRAPHS (ANAKG)




- ✓ ANAKG tworzy złożoną strukturę grafową składającą się z dynamicznych i reaktywnych neuronów i połączeń, aby reprezentować zestaw sekwencji uczących.
- ✓ Neurony agregują wszystkie wystąpienia tych samych elementów, które występują we wszystkich sekwencjach.



Dostrajanie Wag Synaptycznych

- ✓ **Konstrukcja algorytmu dostrajania dla wag synaptycznych w celu lepszego przywołania skojarzonych przechowywanych sekwencji uczących i lepszego uogólniania.**
- ✓ **Unikanie niezamierzonych aktywacji, aby zatrzymać możliwe fałszywie przywoływane elementy sekwencji.**
- ✓ **Skonstruowanie dobrze agregującego modelu do przechowywania skorelowanych sekwencji treningowych.**
- ✓ **Odtworzenie funkcjonalności biologicznej substancji neuronalnej.**

ASN Neurons




- ✓ Połącz neurony kontekstowo, aby wspierać kolejne elementy sekwencji treningowych i automatycznie zbuduj strukturę sieci ANAKG.
- ✓ Agreguj reprezentacje tych samych elementów sekwencji uczących i usuń duplikatu!
- ✓ Licz równoległe asynchronicznie, ponieważ czas wpływa na wyniki sieci ANAKG.
- ✓ Zintegruj pamięć i procesy asocjacyjne.

CEL: Odtworzenie funkcjonalności biologicznej substancji neuronalnej!

Associative Spiking Neurons ASN




- ✓ Zostały opracowane w celu odtworzenia plastyczności i właściwości asocjacyjnych biologicznych neuronów, które działają w czasie.



- ✓ Implementują wewnętrzne procesy neuronalne (IP) i efektywnie zarządzają przetwarzaniem za pomocą wewnętrznych kolejek procesowych (IPQ) i globalnej kolejki zdarzeń (GEQ).
- ✓ Neurony ASN są aktualizowane w dyskretnych momentach czasu, tj. tylko na końcu procesów wewnętrznych, aby zapewnić wysoką wydajność przetwarzania danych!

Jak działają neurony ASN i jak są modelowane?



Stany wewnętrzne neuronów ASN są aktualizowane tylko na końcu Wewnętrznych Procesów (IP) sterowanych przez Globalną Kolejkę Zdarzeń (GEQ).

Model i adaptacja neuronów asocjacyjnych ASN



Skuteczność synaptyczna definiuje skuteczność stymulacji synaps w aktywacji neuronów postsynaptycznych:

$$\delta_{N_m, N_{m+r}} = \sum_{\{(S_m, S_{m+r}) \in S^n \in \mathbb{S}\}} 1 / \left(1 + \frac{\Delta t^A - \Delta t^C}{\theta_{N_{m+r}} \cdot \Delta t^R} \right)^\tau$$

Zależy od:

Δt^A - okres czasu, który upłynął między stymulacją synapsy między neuronami N_m i N_{m+r} oraz aktywacją neuronu postsynaptycznego N_{m+r} ;

podczas treningu zestawu sekwencji treningowych $\mathbb{S} = \{S^1, \dots, S^N\}$;

Δt^C - okres czasu potrzebny do naładowania i aktywacji neuronu postsynaptycznego N_{m+r} po stymulacji synapsy między neuronami N_m i N_{m+r} (tutaj Δt^C);

$\Delta t^R = 200\text{ms}$ - maksymalny okres czasu, w którym neuron postsynaptyczny N_{m+r} powraca do stanu spoczynku po naładowaniu podprogowym, które nie było jednak wystarczająco silne, aby aktywować ten neuron;

$\theta_{N_{m+r}} = 1$ - próg aktywacji neuronu postsynaptycznego N_{m+r} ;

$\tau = 4$ - czynnik wpływający na kontekst zmieniający wpływ wcześniej aktywowanych i połączonych neuronów na neuron postsynaptyczny N_{m+r} .

Jak w rzeczywistości działają neurony
i od czego zależy ich działanie?

Model i adaptacja neuronów asocjacyjnych ASN



Skuteczność synaptyczna δ i liczba aktywacji η neuronu presynaptycznego N_m podczas uczenia zbioru sekwencji uczących \mathcal{S} jest wykorzystana do zdefiniowania przepuszczalności synaptycznej p :

$$p = \theta \cdot \frac{2 \cdot \delta}{\eta + \delta}$$

lub

$$p = \theta \cdot \frac{\eta \cdot \delta}{\eta \cdot \delta + \eta^2 - \delta^2}$$

Który jest ostatecznie używany do obliczania wag synaptycznych:

$$w = c \cdot p \cdot m$$

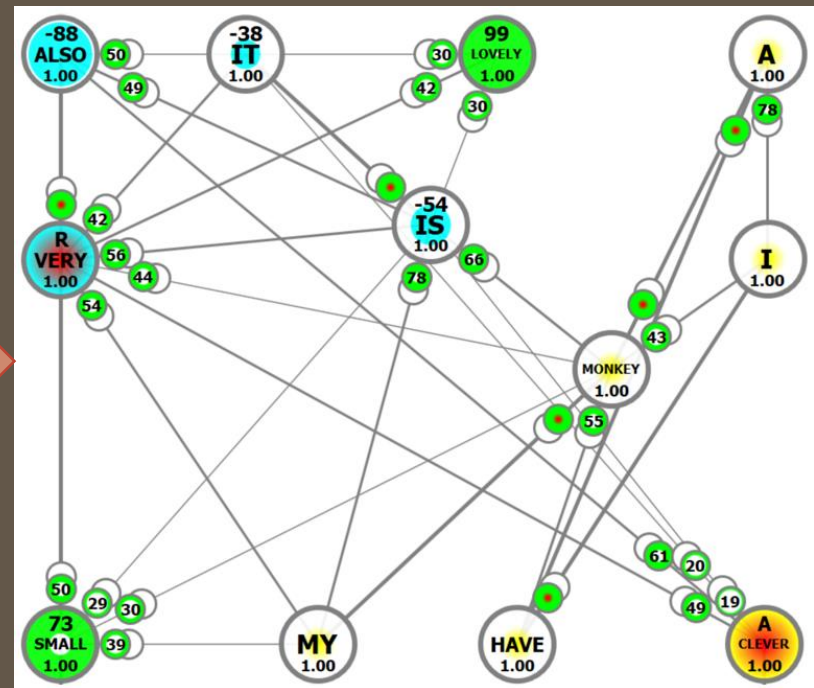
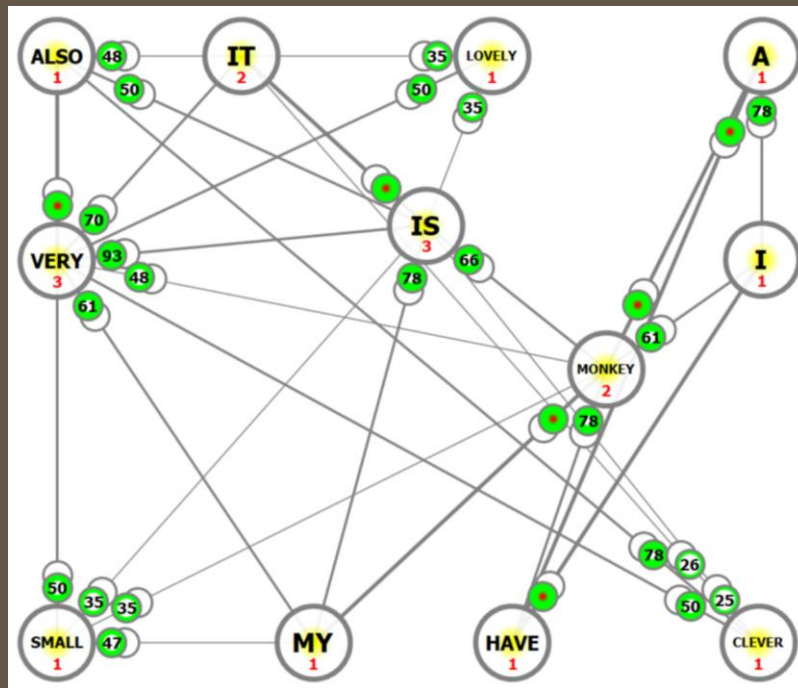
gdzie c to wpływ synaptyczny: pobudzający ($c = 1$) lub hamujący/tłumiący ($c = -1$), a m jest współczynnikiem multiplikacji połączeń modelującym liczbę synaps łączących neurony presynaptyczne i postsynaptyczne.

Adaptacja i dostrajanie neuronów asocjacyjnych ASN



Wagi obliczone w przedstawiony sposób są wystarczająco dobre dla podstawowego zestawu wag w złożonych sieciach neuronowych:

I have a monkey. My monkey is very small. It is very lovely. It is also very clever.



Proces dostrajania wag pozwala uzyskać jeszcze lepsze wyniki przywoływania kolejnych elementów sekwencji dzięki niewielkiej modyfikacji współczynników multiplikacji synaps m .

Proces dostrajania wag sieci neuronowych ANAKG



Dwa powtarzające się etapy **procesu strojenia**:

1. Wszystkie niepożądane i przedwczesne aktywacje neuronów są usuwane dla wszystkich sekwencji treningowych dzięki **operacjom osłabiającym**.
2. Konflikty między skorelowanymi sekwencjami treningowymi są precyzyjnie dostosowywane za pomocą **operacji wzmacniających**.

W tym celu definiujemy: s_{last}^{charge} - siłę ostatniego bodźca,

x - poziom naładowania w momencie, gdy przyszedł ostatni bodziec

x_{all}^{max} - maksymalny dynamiczny poziom naładowania stymulowanego neuronu

$$x_{all}^{max} = \begin{cases} x + s_{last}^{charge} & \text{if } x + s_{last}^{charge} > x_{all}^{max} \\ x_{all}^{max} & \text{otherwise} \end{cases}$$

$x_{context}^{max}$ - poprzedni maksymalny poziom naładowania określający kontekst ostatniego bodźca, który powinien aktywować neuron:

$$x_{context}^{max} = x_{all}^{max} - s_{last}^{charge}$$

Prawidłowa aktywacja neuronu zakłada, że

$$x_{context}^{max} < \theta \leq x_{context}^{max} + s_{last}^{charge}$$

Na tej podstawie możemy zdefiniować operacje wzmacniające i osłabiające wagi w trakcie procesu dostrajania ANAKGów.

Operacja Osłabiania



Operacja osłabienia definiuje, jak maleje współczynnik mnożenia m , gdy neuron jest aktywowany w niewłaściwym kontekście lub przedwcześnie w zredukowanym kontekście:

$$\gamma = \begin{cases} \frac{\theta}{(x_{all}^{max} + \varepsilon)} & \text{dla niepożądanych aktywacji} \\ \frac{\theta}{(x_{context}^{max} + \varepsilon)} & \text{dla przedwczesnych aktywacji} \end{cases}$$

$$m = m \cdot \gamma$$

$$w = c \cdot p \cdot m$$

Współczynniki mnożenia m nieprawidłowych aktywacji muszą zostać obniżone, aby nie powodowały nadmiarowe aktywacje neuronów z poza przywoływanej sekwencji uczącej, tj. w niewłaściwym kontekście stymulacji kolejnych neuronów.

Operacje osłabienia zawsze rozpoczynają i kończą proces strojenia sieci ANAKG.

Operacja Wzmacniania



Operacja wzmocnienia definiuje, w jaki sposób mnożnik m wzrasta, gdy neuron nie jest aktywowany w odpowiednim kontekście dla wszystkich poprzedników sekwencji treningowej lub zbyt późno:

$$\gamma = \frac{\theta}{x_{all}^{max} - \varepsilon}$$

$$m = m \cdot \gamma$$

$$w = c \cdot p \cdot m$$

Operacja wzmacniająca dąży do stymulacji następnego elementu sekwencji. Czasami jednak nie jest to korzystne, jeśli początkowy kontekst nie jest unikalny, np. gdy istnieje wiele sekwencji uczących, które zaczynają się od tych samych podsekwencji elementów.

Operacje wzmacniania pozwalają na przywołanie kolejnych elementów sekwencji uczących, gdy kontekst stymulacji jest unikalny.

Wyniki Eksperymentów



Uzyskane wyniki potwierdzają, że proponowany proces strojenia jest korzystny i zapewnia lepszą adaptację wag, pozwalając na lepsze wywoływanie sekwencji z sieci ANAGK.

Input Stimulations	ANAGK Responses	Tuned ANAGK Responses
I also	I also have a	I also have a monkey
I have	I have a	I have a
I have an	I have a an old sister	I have an old sister
I have a young	I have a young brother	I have a young brother
I also have a big	I also have a big cat	I also have a big cat
You	You have a cat	You have a cat as well
My son	My son also has a monkey	My son also has a monkey
My brother	My brother	My brother is small
My monkey	My monkey	My monkey is
My monkey is very	My monkey is very small	My monkey is very small
It can	It can jump very quickly	It can jump very quickly
It is also	It is also very	It is also very clever
It is very	It is very	It is very lovely
It learns	It learns	It learns quickly
It likes to	It likes to sit on my his lamp monkey is small	It likes to sit on his lamp
She is very	She is very	She is very lovely
She likes to	She likes to sit on my his lamp monkey is small	She likes to sit in the library and read books
He	He has a monkey	He has a monkey
He has	He has a monkey	He has a monkey and dogs
His monkey is	His monkey is	His monkey is small
His monkey is small	His monkey is small	His monkey is small as well
We have lovely	We have lovely	We have lovely dogs

ZBIÓR TRENINGOWY:
*I have a monkey.
My monkey is very small.
It is very lovely.
It likes to sit on my head.
It can jump very quickly.
It is also very clever.
It learns quickly.
My monkey is lovely.
I also have a big cat.
My son also has a monkey.
It likes to sit on his lamp.
I have an old sister.
She is very lovely.
My sister has a small cat.
She likes to sit in the library and read books.
She quickly learns languages.
My sister has a cat.
It is very small.
You have a cat as well.
It is big.
I have a young brother.
My brother is small.
He has a monkey and dogs.
His monkey is small as well.
We have lovely dogs.*



WNIOSKI

- ✓ Przedstawiony algorytm dostrajania wag sieci ANAKG dokładniej dostosowuje wagi asocjacyjnych neuronów pulsacyjnych ASN i pozwala uzyskać lepsze przywołanie sekwencji treningowych.

ANAKG:	UNTUNED	FINE-TUNED
Evaluation Results	correctly recalled	correctly recalled
4 sequences	85%	100%
25 sequences	76%	95%
hundreds of very correlated sequences	54%	91%

Literatura i Bibliografia

1. **A. Horzyk, J. A. Starzyk, J. Graham, *Integration of Semantic and Episodic Memories***, IEEE Transactions on Neural Networks and Learning Systems, Vol. 28, Issue 12, Dec. 2017, pp. 3084 - 3095, 2017, [DOI: 10.1109/TNNLS.2017.2728203](https://doi.org/10.1109/TNNLS.2017.2728203).
2. **A. Horzyk, J. A. Starzyk, *Associative Fine-Tuning of Biologically Inspired Active Neuro-Associative Knowledge Graphs***, In: 2018 IEEE Symposium Series on Computational Intelligence (SSCI 2018), IEEE Xplore, pp. 2068-2075, 2018.
3. **A. Horzyk, J.A. Starzyk, *Fast Neural Network Adaptation with Associative Pulsing Neurons***, IEEE Xplore, In: 2017 IEEE Symposium Series on Computational Intelligence, pp. 339 -346, 2017, [DOI: 10.1109/SSCI.2017.8285369](https://doi.org/10.1109/SSCI.2017.8285369).
4. **A. Horzyk, *Deep Associative Semantic Neural Graphs for Knowledge Representation and Fast Data Exploration***, Proc. of KEOD 2017, SCITEPRESS Digital Library, pp. 67 - 79, 2017, [DOI: 10.13140/RG.2.2.30881.92005](https://doi.org/10.13140/RG.2.2.30881.92005).
5. **A. Horzyk, *Neurons Can Sort Data Efficiently***, Proc. of ICAISC 2017, Springer-Verlag, LNAI, 2017, pp. 64 - 74, [ICAISC BEST PAPER AWARD 2017](https://www.springer.com/icaisc) sponsored by Springer.
6. **A. Horzyk, J. A. Starzyk and Basawaraj, *Emergent creativity in declarative memories***, IEEE Xplore, In: 2016 IEEE Symposium Series on Computational Intelligence, Greece, Athens: Institute of Electrical and Electronics Engineers, Curran Associates, Inc. 57 Morehouse Lane Red Hook, NY 12571 USA, 2016, ISBN 978-1-5090-4239-5, pp. 1 - 8, [DOI: 10.1109/SSCI.2016.7850029](https://doi.org/10.1109/SSCI.2016.7850029).
7. **Horzyk, A., *How Does Generalization and Creativity Come into Being in Neural Associative Systems and How Does It Form Human-Like Knowledge?***, Elsevier, Neurocomputing, Vol. 144, 2014, pp. 238 - 257, [DOI: 10.1016/j.neucom.2014.04.046](https://doi.org/10.1016/j.neucom.2014.04.046).
8. **A. Horzyk, *Innovative Types and Abilities of Neural Networks Based on Associative Mechanisms and a New Associative Model of Neurons*** - Invited talk at ICAISC 2015, Springer-Verlag, [LNAI 9119](https://www.springer.com/icaisc), 2015, pp. 26 - 38, [DOI 10.1007/978-3-319-19324-3_3](https://doi.org/10.1007/978-3-319-19324-3_3).
9. **A. Horzyk, *Human-Like Knowledge Engineering, Generalization and Creativity in Artificial Neural Associative Systems***, Springer-Verlag, AISC 11156, ISSN 2194-5357, ISBN 978-3-319-19089-1, ISBN 978-3-319-19090-7 (eBook), Springer, Switzerland, 2016, pp. 39 – 51, [DOI 10.1007/978-3-319-19090-7](https://doi.org/10.1007/978-3-319-19090-7).



Adrian Horzyk

horzyk@agh.edu.pl

Google: [Horzyk](https://www.google.com/search?q=Horzyk)



AGH

**University of Science
and Technology
in Krakow, Poland**