

DASNG

Deep Associative Semantic Neural Graphs

Głębokie Skojarzeniowo-Semantyczne Grafy Neuronowe
do budowy grafowych asocjacyjnych baz danych



METODY INŻYNIERII WIEDZY



Akademia Górniczo-Hutnicza w Krakowie

Adrian Horzyk

horzyk@agh.edu.pl

Google: [Horzyk](#)

Asocjacyjne mózgowe procesy



mogą zostać użyte do organizacji danych w głębokich strukturach neuronowych.

Cele i Innowacyjne Podejście



- Implementacja **mechanizmów skojarzeniowych** inspirowanych mózgiem.
- Konstrukcja **głębokich skojarzeniowo-semantycznych neuronowych struktur grafowych DASNG** w celu asocjacyjnej reprezentacji danych przechowywanych w relacyjnych i nierelacyjnych bazach danych.
- Wprowadzenie innowacyjnych **asocjacyjnych neuronów impulsowych** zdolnych szybko **wskazać powiązane dane i encje** w celu **wnioskowania**.
- **Innowacyjny** sposób przechowywania, organizacji i dostępu do danych, połączony z zarządzaniem danymi, umożliwiając **agregację, integrację i skojarzenie** różnych kolekcji danych przechowywanych w bazach danych.
- Implementacja **nowego mechanizmu dostępu do danych w czasie stałym**.
- Efektywna **bezpośrednia reprezentacja** wzbogaconych i ważonych relacji w głębokich strukturach neuronowych, które reprezentują zarówno **horyzontalne jak i wertykalne relacje pomiędzy danymi i encjami**.
- **Zastąpienie czasochłonnych procedur algorytmicznych strukturą** która znacząco **redukuje złożoność obliczeniową** różnych operacji na danych oraz całych encjach, w szczególności operacje wyszukiwania, dodawania, usuwania i aktualizacji danych.



Ograniczenia Współczesnych Komputerów





Współczesne komputery:

- posiadają **ograniczenia tzw. Maszyny Turinga** czyli modelu obliczeniowego, stojącego u podstaw konstrukcji współczesnych komputerów, algorytmów oraz metod obliczeniowych, które nie korzystają za **paradygmatu czasu**;
- wykorzystują **pamięć RAM o strukturze liniowej**, która utrudnia operacje na nieliniowych strukturach danych, tj. grafy;
- **separują dane i programy** oraz **pamięć od procesora CPU czy GPU**;
- wywołują i wykonują instrukcje (rozkazy) **sekwencyjnie**;
- udostępniają **równoległość synchroniczną** w przypadku wykorzystania GPU, czyli taką która nie współgra ze sposobem działania neuronów w mózgu.



≠





Mózg i Neurony



- ✓ Działają **równolegle** i często **asynchronicznie**.
- ✓ **Automatycznie, szybko i kontekstowo kojarzą** dane i obiekty (encje).
- ✓ Wykorzystują skomplikowaną **grafową** strukturę pamięci.




- ✓ **Integrują pamięć z programami**, które wykorzystują uformowaną wcześniej **wiedzę do wnioskowania i wywoływania skojarzeń**.
- ✓ **Wykorzystują czas do temporalnych i kontekstowych obliczeń**.
- ✓ Nie są ograniczone obliczeniowo przez **maszynę Turinga**.



Wybrane Wady Modelu Relacyjnego i Relacyjnych Baz Danych



✓ Reprezentacja relacji horyzontalnych pomiędzy encjami (obiektami)



Nurse ID	First Name	Last Name	Seniority
N1	Amy	Moon	12
N2	Rose	Jolie	18
N3	Kate	Ford	24
N4	Lisa	Brown	9
N5	Sara	Pitt	4
N6	Kate	Lopez	12

Doctor ID	First Name	Last Name	Seniority	Specialization
D1	Tom	Hanks	18	orthopedics
D2	Jack	Brown	15	surgery
D3	Lisa	Ford	23	pediatrician
D4	Tom	Trump	35	pediatrician
D5	Kate	Smith	7	surgery
D6	Amy	Hanks	12	surgery

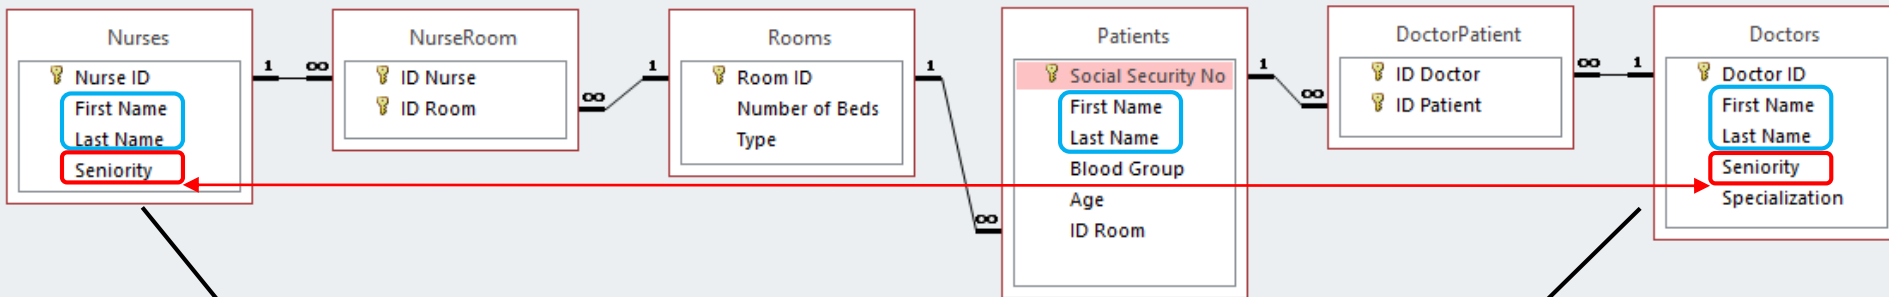
1. Brak reprezentacji **relacji wertykalnych pomiędzy encjami (obiektami)** w tabelach.
2. Konieczność znalezienia **relacji wertykalnych**, tj. porządek, podobieństwo...
3. Im więcej obiektów (encji) w tabelach tym trudniej przetwarzać dane (**BIG DATA**).
4. Nieefektywna reprezentacja **duplikatów** w tej samej lub różnych tabelach.
5. **Nie powiązane atrybuty i dane** w różnych tabelach opisujące te same kategorie.



Konsekwencje Wad Modelu Relacyjnego



✓ Reprezentacja relacji horyzontalnych pomiędzy encjami (obiektami)



Nurse ID	First Name	Last Name	Seniority
N1	Amy	Moon	12
N2	Rose	Jolie	18
N3	Kate	Ford	24
N4	Lisa	Brown	9
N5	Sara	Pitt	4
N6	Kate	Lopez	12

Doctor ID	First Name	Last Name	Seniority	Specialization
D1	Tom	Hanks	18	orthopedics
D2	Jack	Brown	15	surgery
D3	Lisa	Ford	23	pediatrician
D4	Tom	Trump	35	pediatrician
D5	Kate	Smith	7	surgery
D6	Amy	Hanks	12	surgery

1. Musimy tworzyć różne **procedury wyszukiwania (SELECT)** do wyciągnięcia informacji.
2. Każde wyszukiwanie **kosztuje czas i moc obliczeniową** ponieważ odbywa się **pętli(ach)**.
3. Wyniki wyszukiwania zwykle **nie są zapisywane** lub są **nieprzydatne** do następnych operacji.
4. Przechowywane są często **duplikaty** danych, czyli **brak ich agregacji** zwiększa koszt operacji.
5. Musimy **wykorzystywać indeksy** w celu optymalizacji dalszych operacji wyszukiwania, gdyż dane **nie są uporządkowane** względem swoich wartości.



Asocjacyjna Transformacja Relacyjnej Bazy Danych




Social Security No	First Name	Last Name	Blood Group	Age	ID Room
17102595834	Jack	Hanks	0	0	R6
17102785603	Nina	Rock	AB	0	R6
73040593020	Tom	Kite	A	44	R4
84021205010	Tom	Ford	AB	33	R1
90503029943	Emy	Cruise	A	27	R2
94051382054	Lisa	White	B	23	R3
94080639502	Paula	Smith	B	23	R2

Nurse ID	First Name	Last Name	Seniority
N1	Amy	Moon	12
N2	Rose	Jolie	18
N3	Kate	Ford	24
N4	Lisa	Brown	9
N5	Sara	Pitt	4
N6	Kate	Lopez	12

Doctor ID	First Name	Last Name	Seniority	Specialization
D1	Tom	Hanks	18	orthopedics
D2	Jack	Brown	15	surgery
D3	Lisa	Ford	23	pediatrician
D4	Tom	Trump	35	pediatrician
D5	Kate	Smith	7	surgery
D6	Amy	Hanks	12	surgery

Baza Danych Mały Szpital

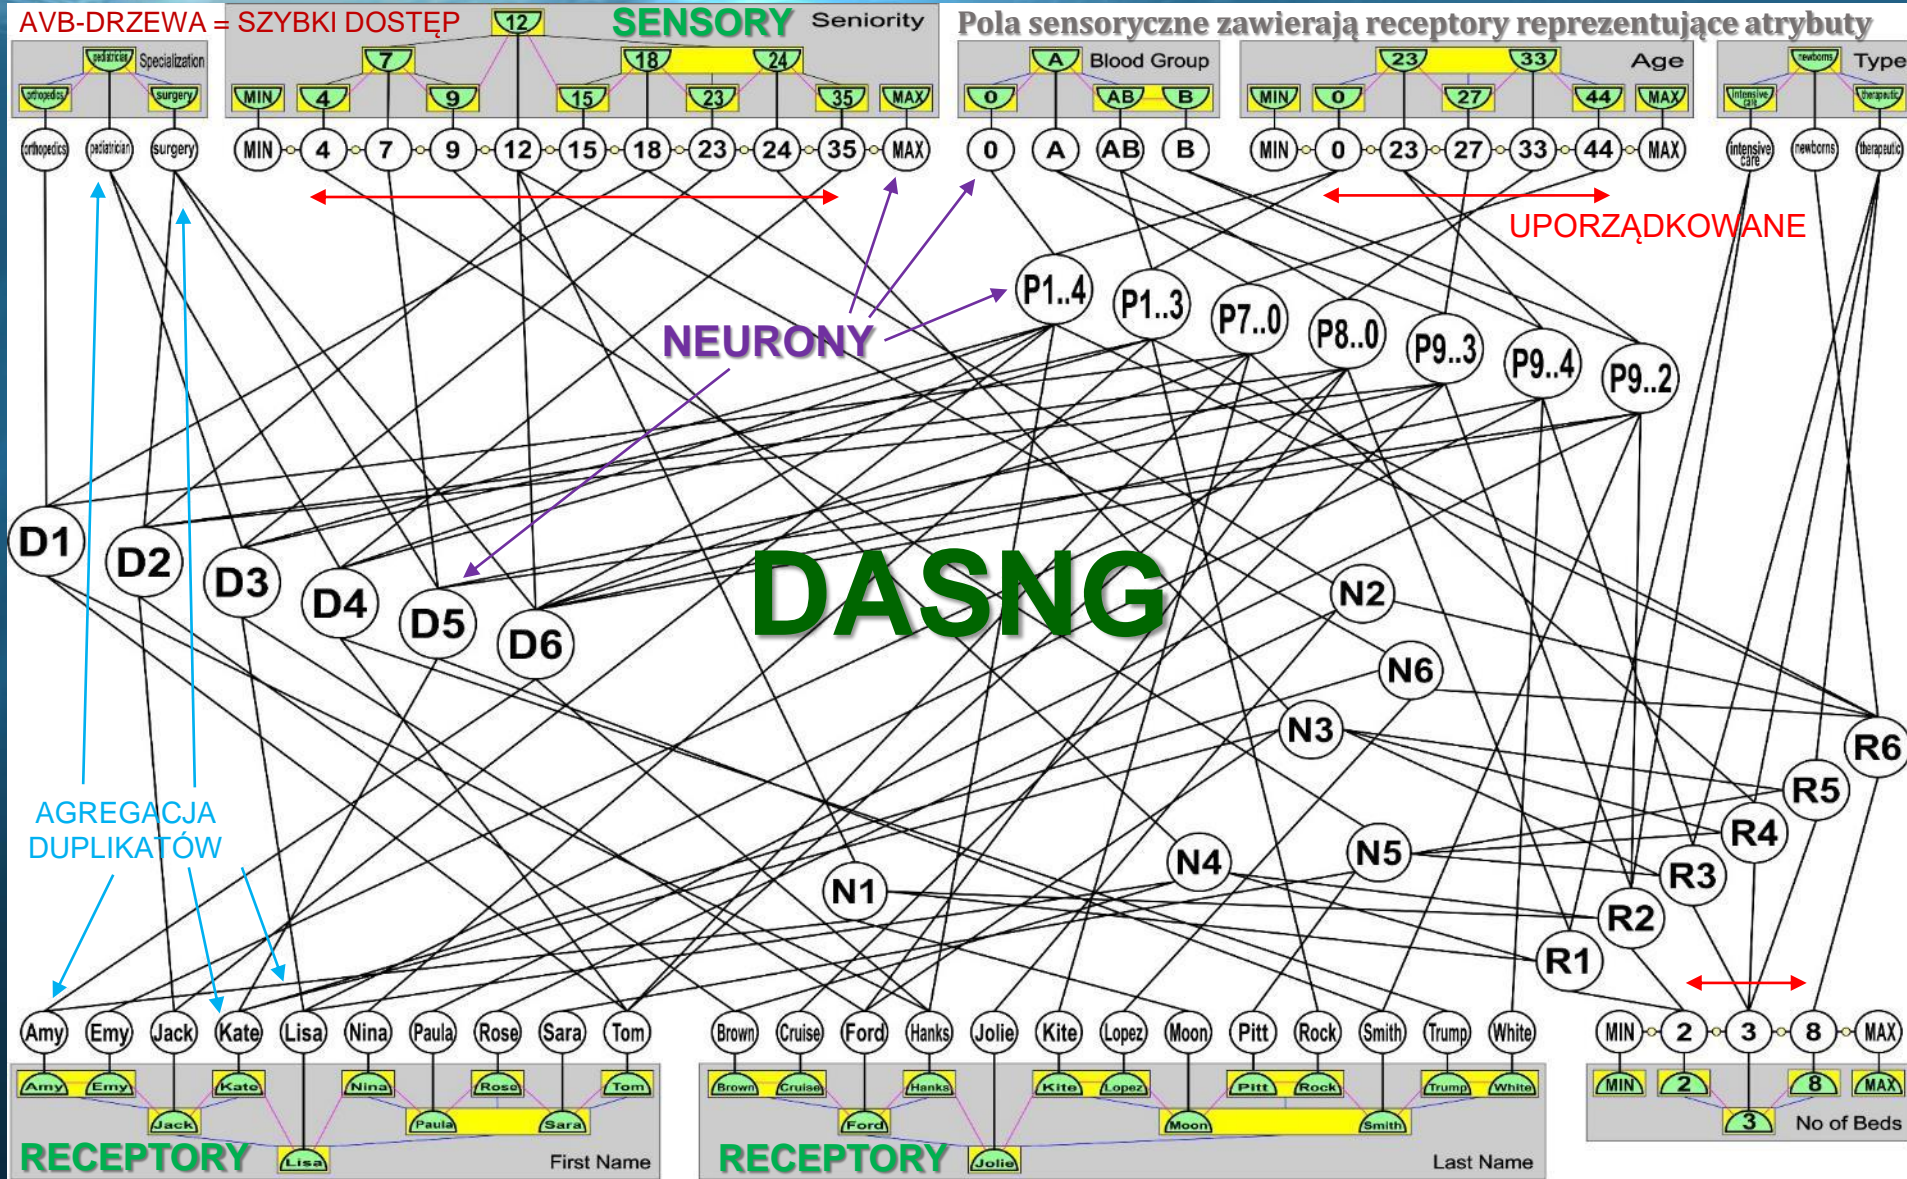


Zastępowanie Operacji Wyszukiwana Asocjacyjną Strukturą Grafową



- W celu przyspieszenia operacji wyszukiwania, powinniśmy **skojarzyć ze sobą wszystkie powiązane dane i obiekty (encje)** reprezentowane w bazie danych:
 - **Posortować** wszystkie porządkowalne wartości atrybutów,
 - **Połączyć** obiekty reprezentujące relacje wiele-do-wielu bezpośrednio,
 - **Zagregować** reprezentancje wszystkich duplikatów wartości atrybutów dla tych samych kategorii niezależnie od ich lokalizacji w tabelach bazodanowych,
 - **Zagregować** reprezentancje wszystkich duplikatów obiektów.
- W konsekwencji tego wszystkie obiekty będą **szybko dostępne i nie będzie potrzebne ich czasochłonne przeszukiwanie, indeksowanie ani porównywanie w wielu zagnieżdżonych pętlach obliczeniowych.**
- **Wszystkie duplikaty wartości atrybutów** tych samych kategorii występujących w tej samej lub różnych tabelach zostaną zagregowane i reprezentowane przez te same neurony oraz **uporządkowane**, jeśli to możliwe dla danego typu wartości.
- Otrzymamy **asocjacyjną grafową strukturę** reprezentującą wszystkie **horyzontalne** i dodatkowo **wertykalne relacje** pomiędzy danymi i obiektami.
- **Każdy węzeł w grafie** zawiera informację o **ilości zagregowanych duplikatów**.
- **Każde połączenie w grafie** zawiera informację o **sile relacji (asocjacji)** połączonych obiektów lub wartości w zależności od tego, co reprezentują połączone neurony.

Asocjacyjna Grafowa Struktura Danych zastępuje wiele operacji wyszukiwania



DASNG – Głębokie Skojarzeniowo-Semantyczne Grafy Neuronowe



- **D – deep – głębokie** – gdyż przechowują dane i relacje w głębokich wielowarstwowych strukturach neuronowych.
- **A – associative – skojarzeniowe** – odwzorowujące skojarzeniowy sposób działania ludzkiego umysłu, który pozwala na szybki kontekstowy dostęp do skojarzonych danych, np. danych podobnych czy następnych.
- **S – semantic - semantyczne** – wszystkie obiekty przechowywane w tej strukturze są bezpośrednio lub pośrednio semantycznie powiązane.
- **N – neural - neuronowo** – ponieważ wykorzystano tutaj specjalne asocjacyjne neurony, który reprezentują wartości, zakresy lub podzbiory atrybutów, obiekty, ich grupy oraz klasy.
- **G – graph - graph** – ponieważ wszystkie neurony i ich połączenia tworzą rzadką strukturę grafową.



Cechy DASNG



- **DASNG** zawiera **wszystkie relacje horyzontalne** pomiędzy obiektami występujące **w modelu relacyjnym (relacyjnej bazie danych)**.
- **DASNG** w sposób naturalny implementuje **wiele relacji wertykalnych** pomiędzy obiektami dzięki agregacji duplikatów oraz połączeniom pomiędzy neuronami reprezentującymi obiekty podobne (uporzadkowane) wg wartości atrybutów.
- **DASNG** zawsze **dodaje nowe dane kontekstowo** w stosunku do przechowywanych danych w tej asocjacyjnej bazie.
- **DASNG** wykorzystuje asocjacyjne neurony impulsowe do implementacji **reaktywnych** zachowań i automatycznego wnioskowania na podstawie inicjalnego kontekstu stymulacji takiej sieci.
- **DASNG** znacząco obniża złożoność obliczeniową wielu operacji ponieważ **zastępuje operacje wykorzystujące pętle strukturą**.

DEF: Mówimy, że struktura zastępuje operacje wykonywane na innej strukturze, gdy złożoność obliczeniowa operacji na tej strukturze maleje do stałej złożoności obliczeniowej $O(1)$.

Tworzenie DASNG dla BD

Transformuj tylko te tabele, których wszystkie klucze obce są już reprezentowane przez neurony DASNG.

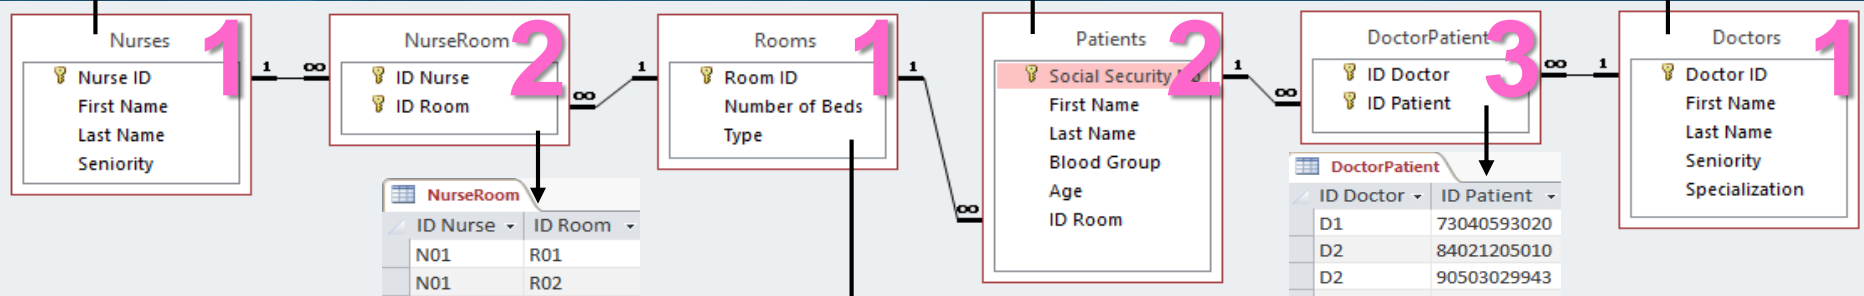


Patients						
	Social Security No	First Name	Last Name	Blood Group	Age	ID Room
+	17102595834	Jack	Hanks	0	0	R6
+	17102785603	Nina	Rock	AB	0	R6
+	73040593020	Tom	Kite	A	44	R4
+	84021205010	Tom	Ford	AB	33	R1
+	90503029943	Emy	Cruise	A	27	R2
+	94051382054	Lisa	White	B	23	R3
+	94080639502	Paula	Smith	B	23	R2

Nurses				
	Nurse ID	First Name	Last Name	Seniority
+	N1	Amy	Moon	12
+	N2	Rose	Jolie	18
+	N3	Kate	Ford	24
+	N4	Lisa	Brown	9
+	N5	Sara	Pitt	4
+	N6	Kate	Lopez	12

Proces asocjacyjnej transformacji

Doctors					
	Doctor ID	First Name	Last Name	Seniority	Specialization
+	D1	Tom	Hanks	18	orthopedics
+	D2	Jack	Brown	15	surgery
+	D3	Lisa	Ford	23	pediatrician
+	D4	Tom	Trump	35	pediatrician
+	D5	Kate	Smith	7	surgery
+	D6	Amy	Hanks	12	surgery



NurseRoom	
ID Nurse	ID Room
N01	R01
N01	R02
N02	R06
N03	R03
N03	R04
N03	R05
N04	R01
N04	R02
N05	R03
N05	R04
N05	R05
N06	R06


Rooms			
Room ID	Number of Beds	Type	
+	R1	2	intensive care
+	R2	2	intensive care
+	R3	3	therapeutic
+	R4	3	therapeutic
+	R5	3	therapeutic
+	R6	8	newborns

DoctorPatient	
ID Doctor	ID Patient
D1	73040593020
D2	84021205010
D2	90503029943
D3	17102595834
D3	17102785603
D4	17102595834
D4	17102785603
D5	90503029943
D5	94080639502
D6	17102595834
D6	73040593020
D6	94051382054
D6	84021205010
D6	94080639502

Możliwa kolejność transformacji tabel

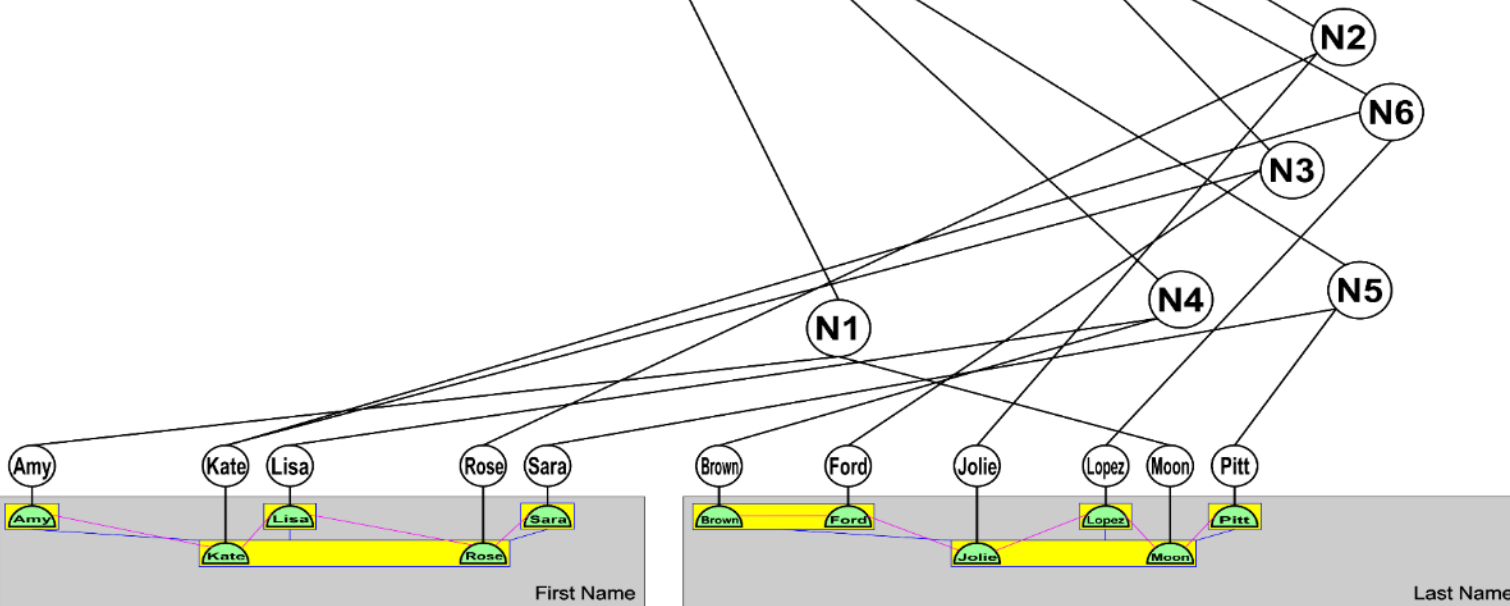
Konstrukcja DASNG dla BD

Tabela NURSES jest dodawana do pustej struktury DASNG.




DASNG + Transformation of the table NURSES

Nurses				
	Nurse ID	First Name	Last Name	Seniority
+	N1	Amy	Moon	12
+	N2	Rose	Jolie	18
+	N3	Kate	Ford	24
+	N4	Lisa	Brown	9
+	N5	Sara	Pitt	4
+	N6	Kate	Lopez	12




Konstrukcja DASNG dla BD

Tabela DOCTORS jest dodawana do struktury DASNG.



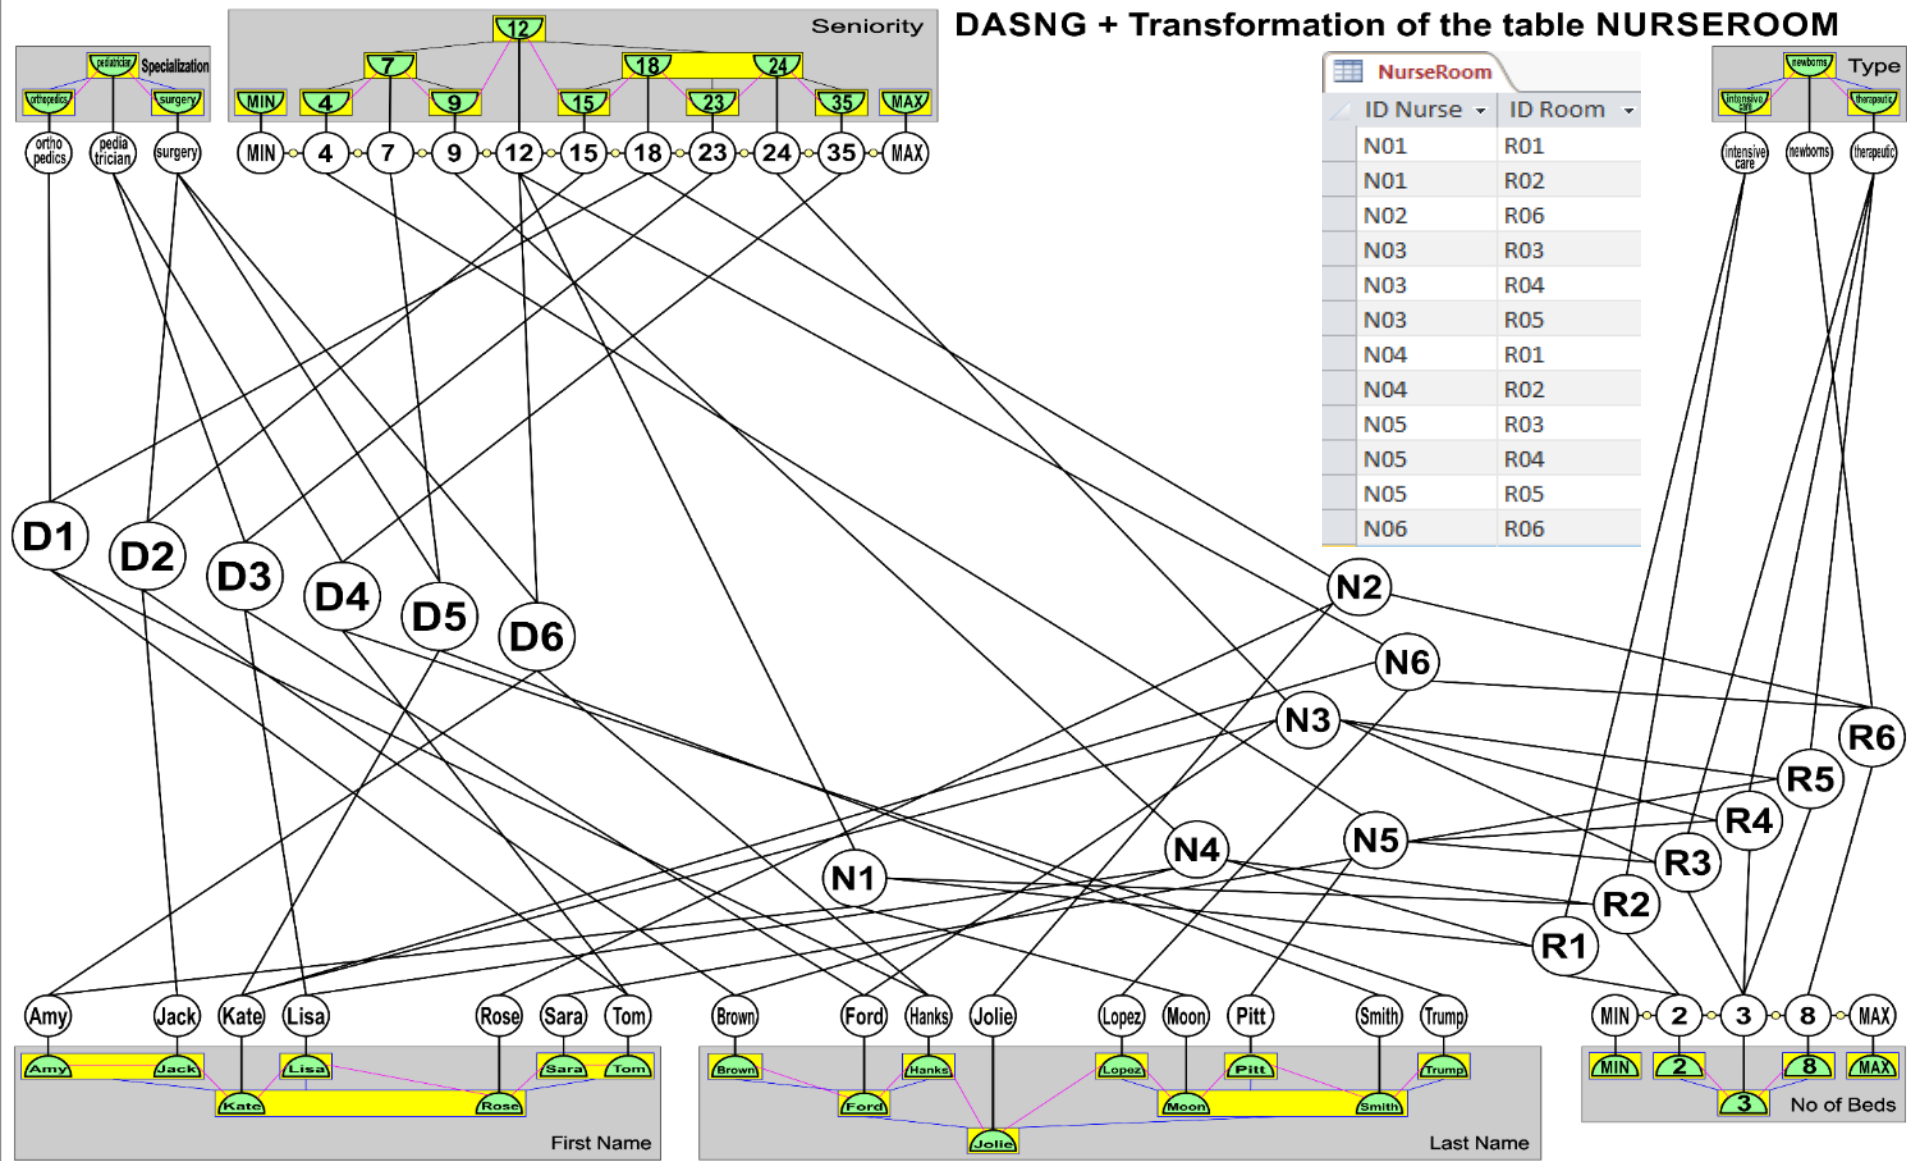
Konstrukcja DASNG dla BD

Tabela ROOMS jest dodawana do struktury DASNG.



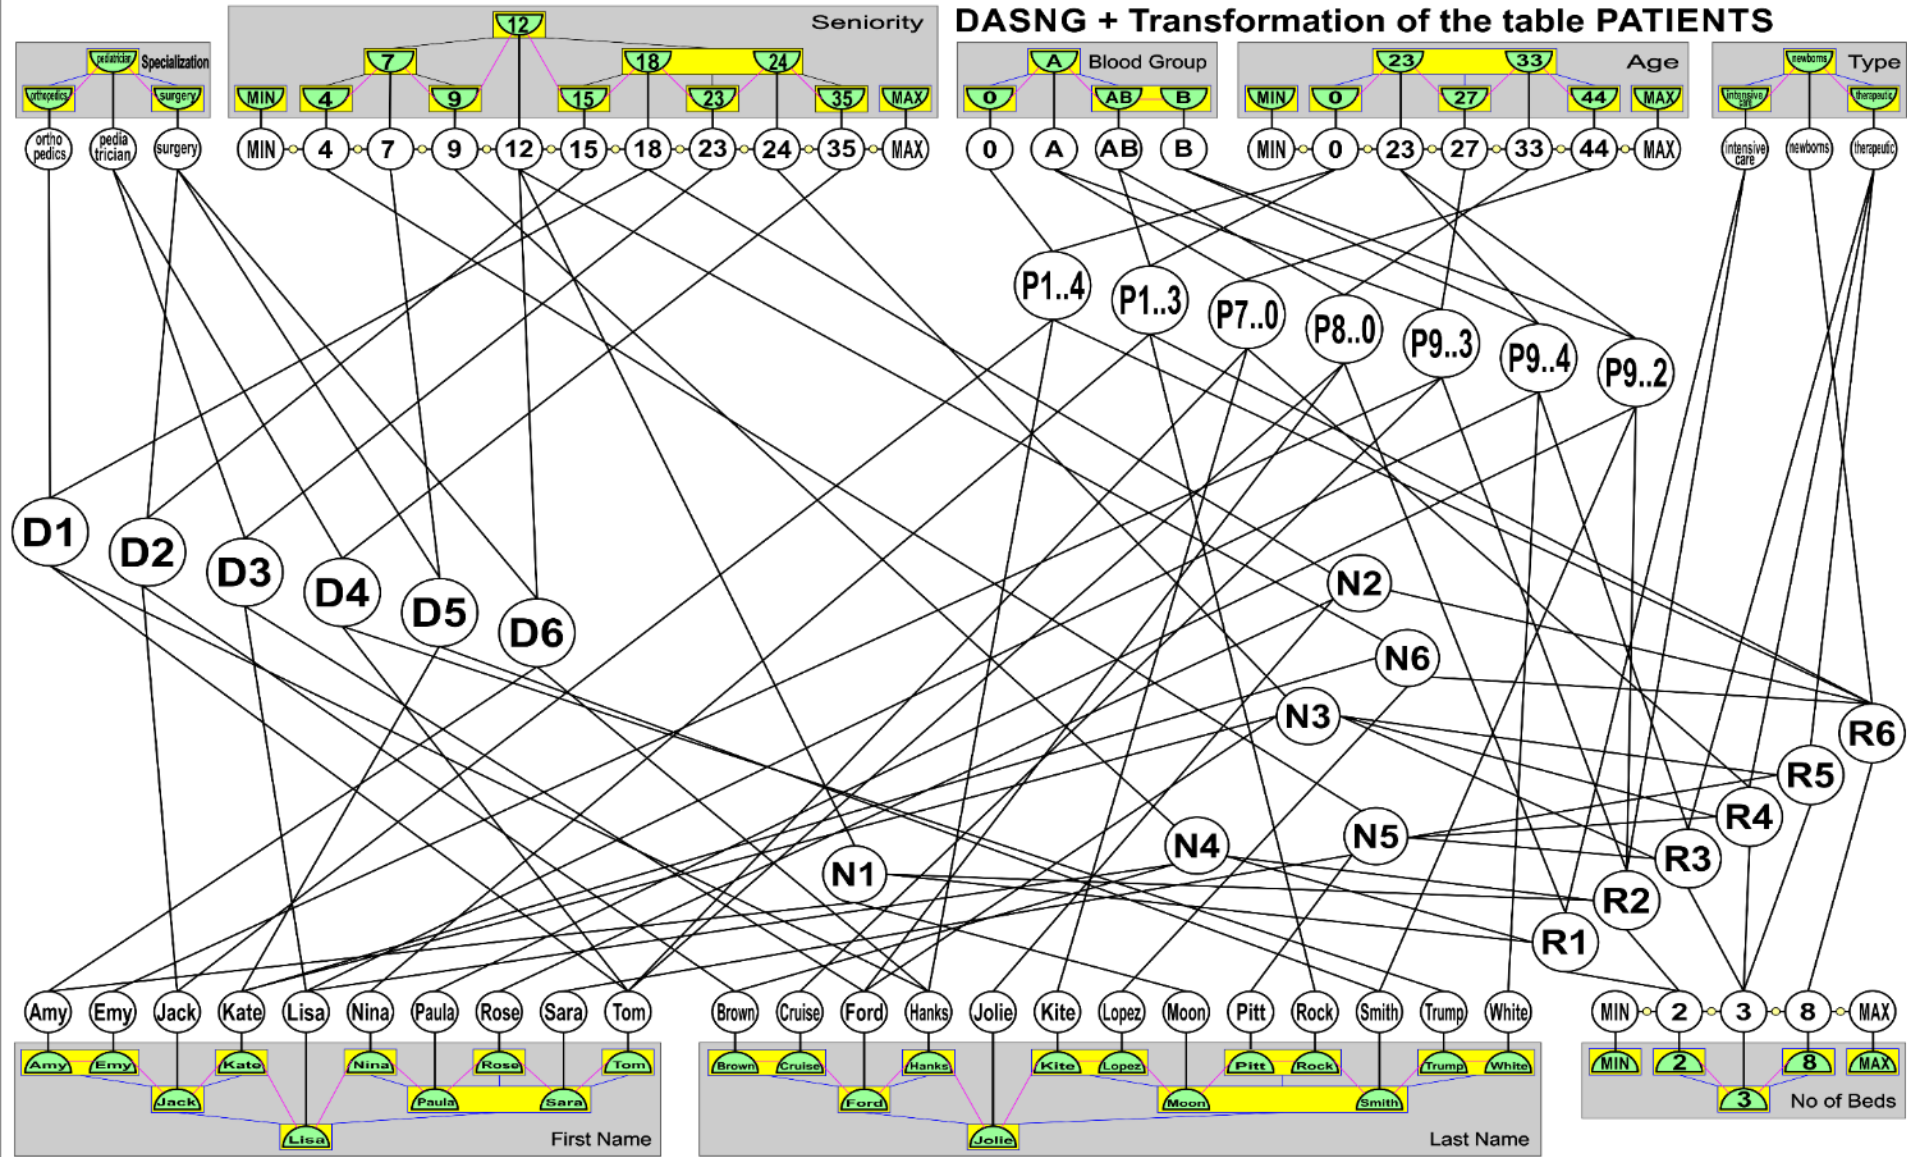
Konstrukcja DASNG dla BD

Tabela NURSEROOM jest dodawana do struktury DASNG.



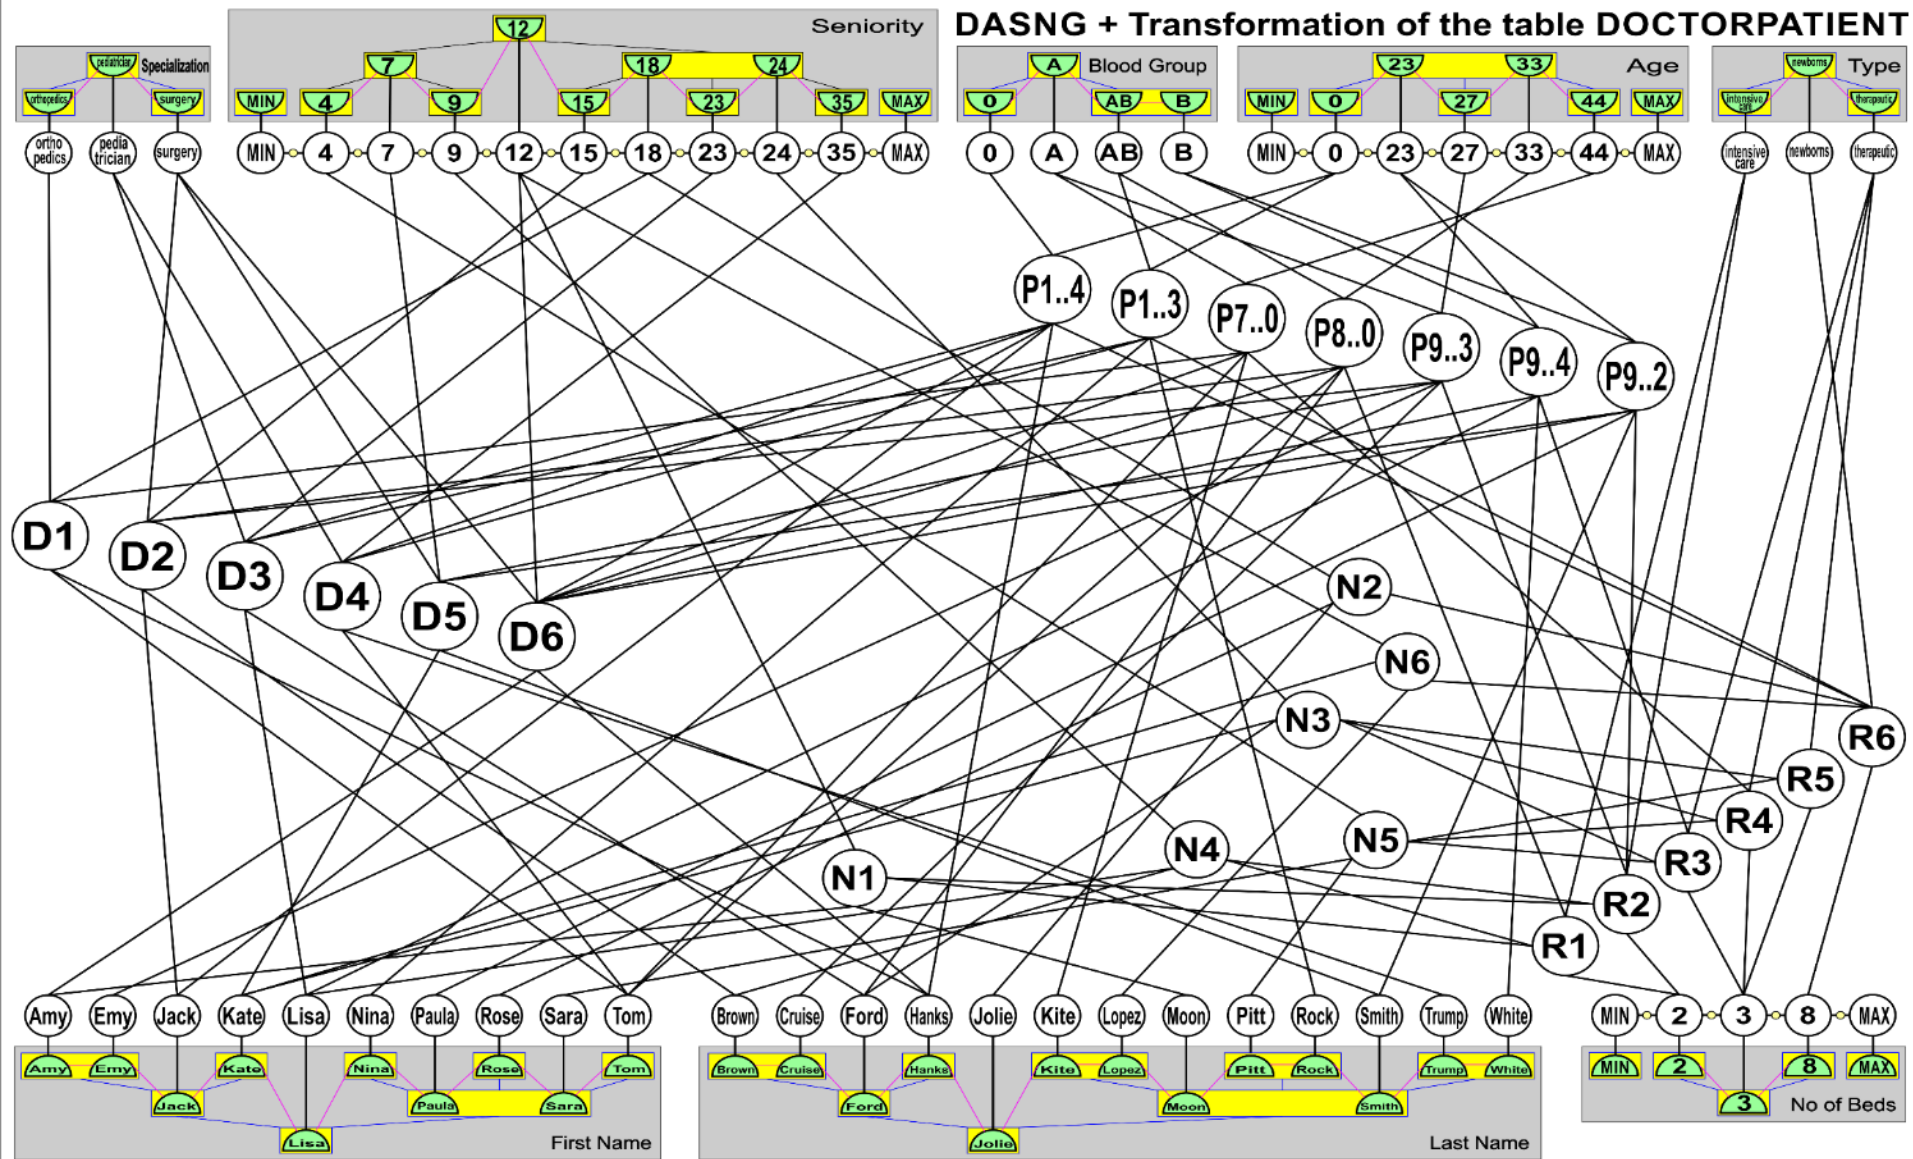
Konstrukcja DASNG dla BD

Tabela PATIENTS jest dodawana do struktury DASNG.



Konstrukcja DASNG dla BD


Tabela DOCTORPATIENT jest dodawana do struktury DASNG.





Wynik Asocjacyjnej Transformacji Bazy Danych do sieci DASNG :

Brak duplikatów oraz wszystkie wartości są posortowane!





DASNG korzysta z AVB-drzew

w celu uzyskania szybkiego dostępu do wartości atrybutów



AVB-drzewo jest strukturą samoorganizującą się i samowyważającą się, pozwalającą na efektywną reprezentację wartości atrybutów, a dzięki temu również na bardzo szybki dostęp do wszystkich obiektów w sieci DASNG.

AVB-drzewa są bardzo podobne do **B-drzew**, lecz **AVB-drzewa dodatkowo agregują i zliczają wszystkie zduplikowane wartości!**


Agregacja wartości zwykle prowadzi do dużo mniejszej struktury **AVB-drzew** niż te osiągalne dla **B-drzew** dla tej samej bazy danych.

Wyszukiwanie jest dzięki temu **szybkie** i zwykle działa **w czasie stałym!**




THE COMPARISON OF AVB-TREE AND B-TREE

counters of duplicates



AVB-TREE




B-TREE

Konstrukcja AVB-drzewa



AVB-drzewa są budowane podobnie jak B-drzewa
lecz ze zliczaniem i agregacją reprezentacji duplikatów:





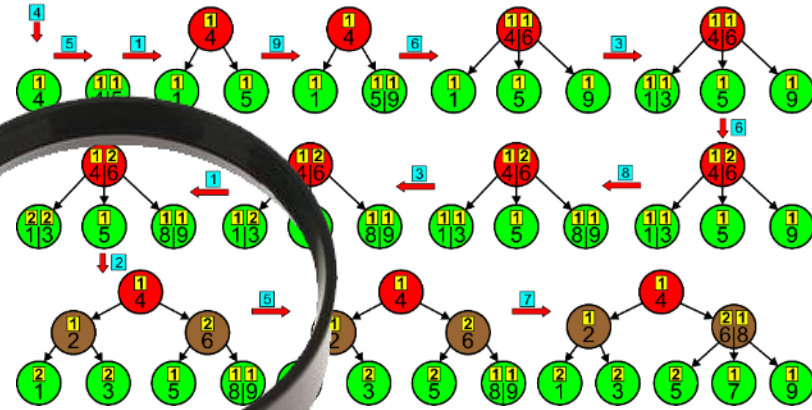
Konstrukcja AVB-drzew



AVB-drzewa są strukturami w pełni **samo-balansującymi się**.

Jeśli któryś z **węzłów** drzewa zawiera w wyniku operacji więcej niż dwa klucze, węzeł jest automatycznie dzielony:

4 5 1 9 6 3 6 8 3 1 2 5 7




Konstrukcja AVB-drzew stopnia 3: Operacja INSERT



1. Rozpoczynając **od korzenia idź rekurencyjnie w dół** wzdłuż krawędzi do potomków **dopóki liść** nie zostanie osiągnięty według następujących reguł:

- jeśli któryś z kluczy przechowywanych w tym węźle **jest równy** wstawianemu kluczowi, **zwiększ licznik tego klucza** i zakończ tą operację,
- w odwrotnym przypadku **idź do lewego dziecka**, jeśli wstawiany klucz **jest mniejszy niż** lewy skrajny klucz przechowywany w tym węźle,
- w odwrotnym przypadku **idź do prawego dziecka**, jeśli wstawiany klucz **jest większy niż** prawy skrajny klucz przechowywany w tym węźle,
- w odwrotnym przypadku **idź do środkowego dziecka**.




Konstrukcja AVB-drzew stopnia 3: Operacja INSERT



2. Kiedy dojdziemy do **liścia**:

- i jeśli wstawiany klucz **jest równy** jednemu z kluczy przechowywanych w tym węźle, **zwiększ licznik** tego klucza i zakończ operację,
- w odwrotnym przypadku **wstaw** wstawiany klucz do tego liścia **w porządku rosnącym kluczy**, zainicjuj jego licznik wartością 1 i przejdź do kroku 3.




Konstrukcja AVB-drzew stopnia 3: Operacja INSERT



3. Jeśli **ilość wszystkich kluczy w węźle jest większa niż dwa**, **podziel** ten liść w następujący sposób:


- pozostaw w dzielonym liściu reprezentację lewego skrajnego (najmniejszego) klucza razem z jego licznikiem;
- **utwórz nowy liść** i pozwól mu reprezentować prawy skrajny (największy) klucz razem z jego licznikiem;
- **przełącz** środkowy klucz razem z jego licznikiem oraz wskaźnikiem do nowo utworzonego liścia **do rodzica** dzielonego liścia, jeśli istnieje, i przejdź do kroku 4;
- jeśli rodzic nie istnieje, **utwórz go** (nowy korzeń AVB-drzewa) i pozwól mu reprezentować ten środkowy klucz razem z jego licznikiem, a następnie utwórz krawędzie łączące go z dzielonym i nowym liściem drzewa; a potem zakończ tą operację.



Konstrukcja AVB-drzew stopnia 3: Operacja INSERT




- Wstaw** przekazany klucz razem z jego licznikiem do tego węzła w porządku rosnącym kluczy według następujących reguł:
 - jeśli klucz przekazany jest z lewej gałęzi, wstaw go z lewej strony istniejący kluczy w węźle;
 - jeśli klucz przekazany jest z prawej gałęzi, wstaw go z prawej strony istniejący kluczy w węźle;
 - jeśli klucz przekazany jest z prawej gałęzi, wstaw go pomiędzy istniejącymi kluczami w węźle.
- Utwórz nową krawędź** do nowego liścia lub węzła wskazywanego przez przekazany wskaźnik i wstaw ten wskaźnik do listy wskaźników dzieci węzła bezpośrednio za wskaźnikiem wskazującym krawędź do dziecka, od którego klucz był przekazany.



Konstrukcja AVB-drzew stopnia 3: Operacja INSERT



6. Jeżeli ilość kluczy w węźle jest większa niż dwa, podziel go na dwa węzły w następujący sposób:
- pozwól istniejącemu węzłowi reprezentować lewy skrajny (najmniejszy) klucz razem z jego licznikiem;
 - **utwórz** nowy węzeł reprezentujący prawy skrajny (największy) klucz razem z jego licznikiem;
 - środkowy klucz razem z jego licznikiem oraz wskaźnikiem do nowo utworzonego węzła **przekaż** do rodzica, jeśli istnieje, i przejść do kroku 4;
 - jeśli rodzic nie istnieje, **utwórz** go (nowy korzeń AVB-drzewa) i pozwól mu reprezentować środkowy klucz razem z jego licznikiem; a następnie utwórz krawędzie do dzielonego i nowego węzła reprezentującego lewy i prawy klucz, a potem zakończ tą operację.




DASNG wykorzystują Receptory oraz Asocjacyjne Neurony Impulsowe




Rzadko i kontekstowo połączone neurony w sieci odgrywają ważną rolę w **procesach asocjacyjnych w mózgu**, gdzie wiedza jest formowana.


The DASNG wykorzystuje model neuronów, który implementuje **paradygmat czasu**.




regular spiking (RS)




intrinsically bursting (IB)




chattering (CH)



fast spiking (FS)





Fundamentalny problem komunikacji neuronów


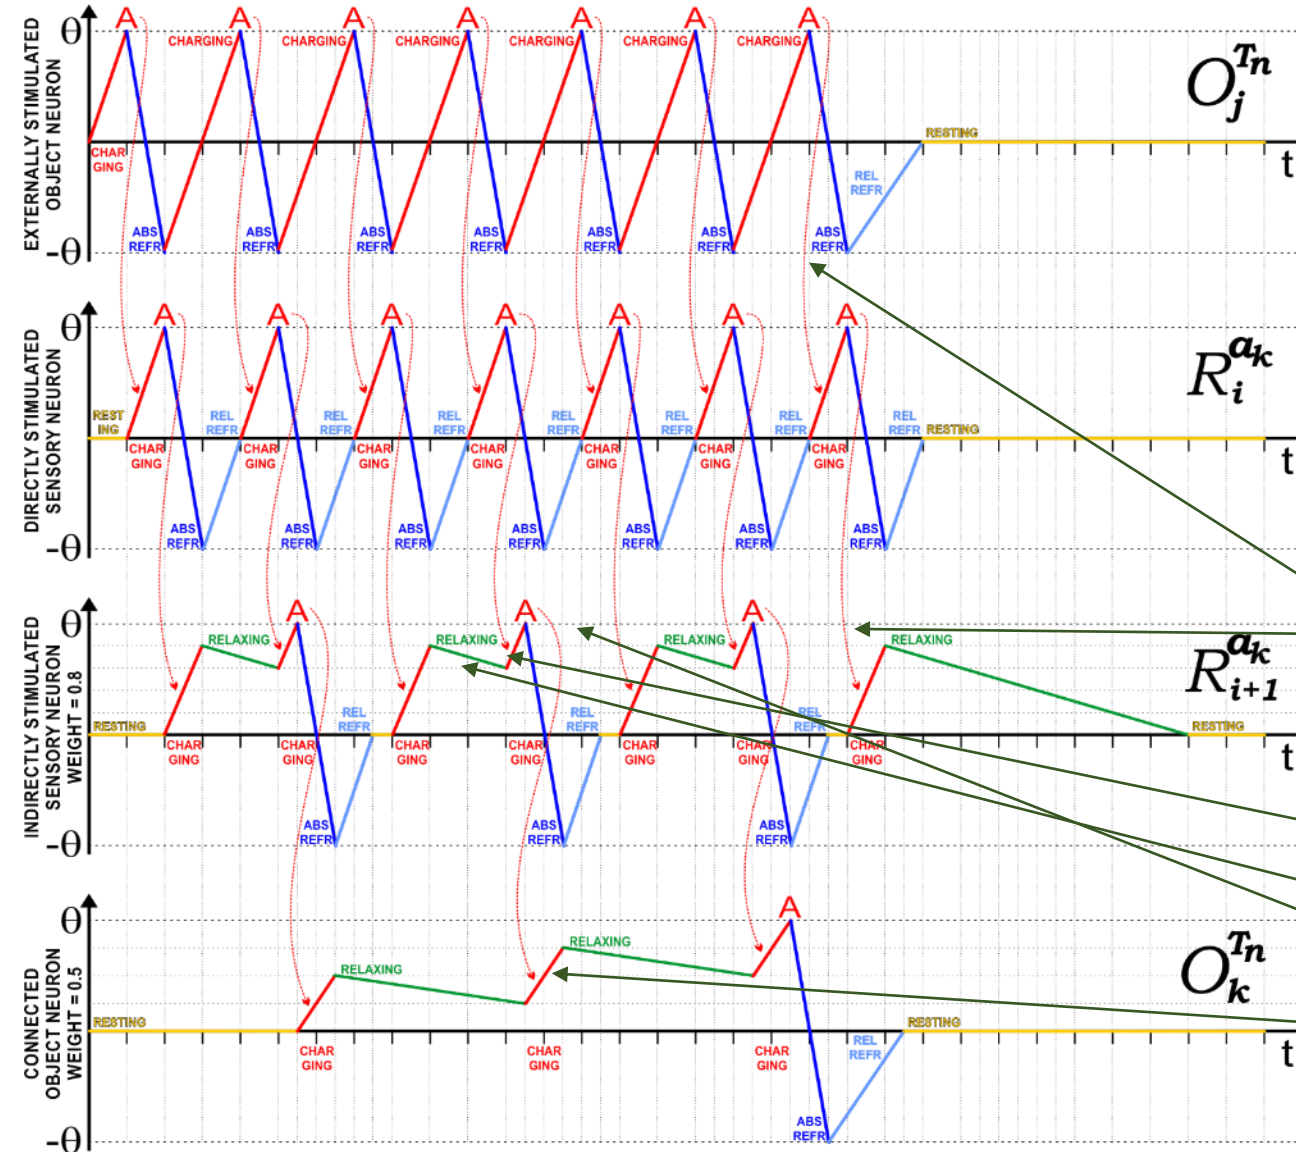


Fundamentalnym problemem jest zaproponowanie takiego modelu neuronu, który wyjaśni **jak informacja jest kodowana i dekodowana w trakcie przesyłu pomiędzy neuronowymi** – czy za pośrednictwem serii pulsów czy potencjałów czynnościowych?

Kodowanie tymczasowe sugeruje, że pojedynczy neuron impulsowy może zastąpić wiele ukrytych neuronów sigmoidalnej sieci neuronowej. Czy to jest prawdą?



Eksperymenty z sieciami DASNG ujawniły, iż **zarówno ilość impulsów jak i czas pomiędzy nimi** mają ważne znaczenie i wpływ na aktywność neuronów postsynaptycznych oraz na to, co neurony reprezentują.

Jak Asocjacyjne Neurony Impulsowe pracują i wpływają na inne neurony?



Każda aktywacja neuronu O_j^{Tn} stymuluje i aktywuje neuron $R_i^{a_k}$, który stymuluje sąsiednie neurony sensoryczne $R_{i+1}^{a_k}$ and $R_{i-1}^{a_k}$ z siłą równą wagom tych połączeń, tzn. 0,8 i 0,6 odpowiednio. Dlatego niezbędna jest min. **dwukrotna stymulacja tych neuronów**, biorąc pod uwagę również ich relaksację, w celu osiągnięcia sumarycznego pobudzenia osiągającego próg aktywacji $\theta = 1$. To pozwala na rozpoczęcie stymulacji kolejnych połączonych neuronów, np. neuronu O_k^{Tn} .


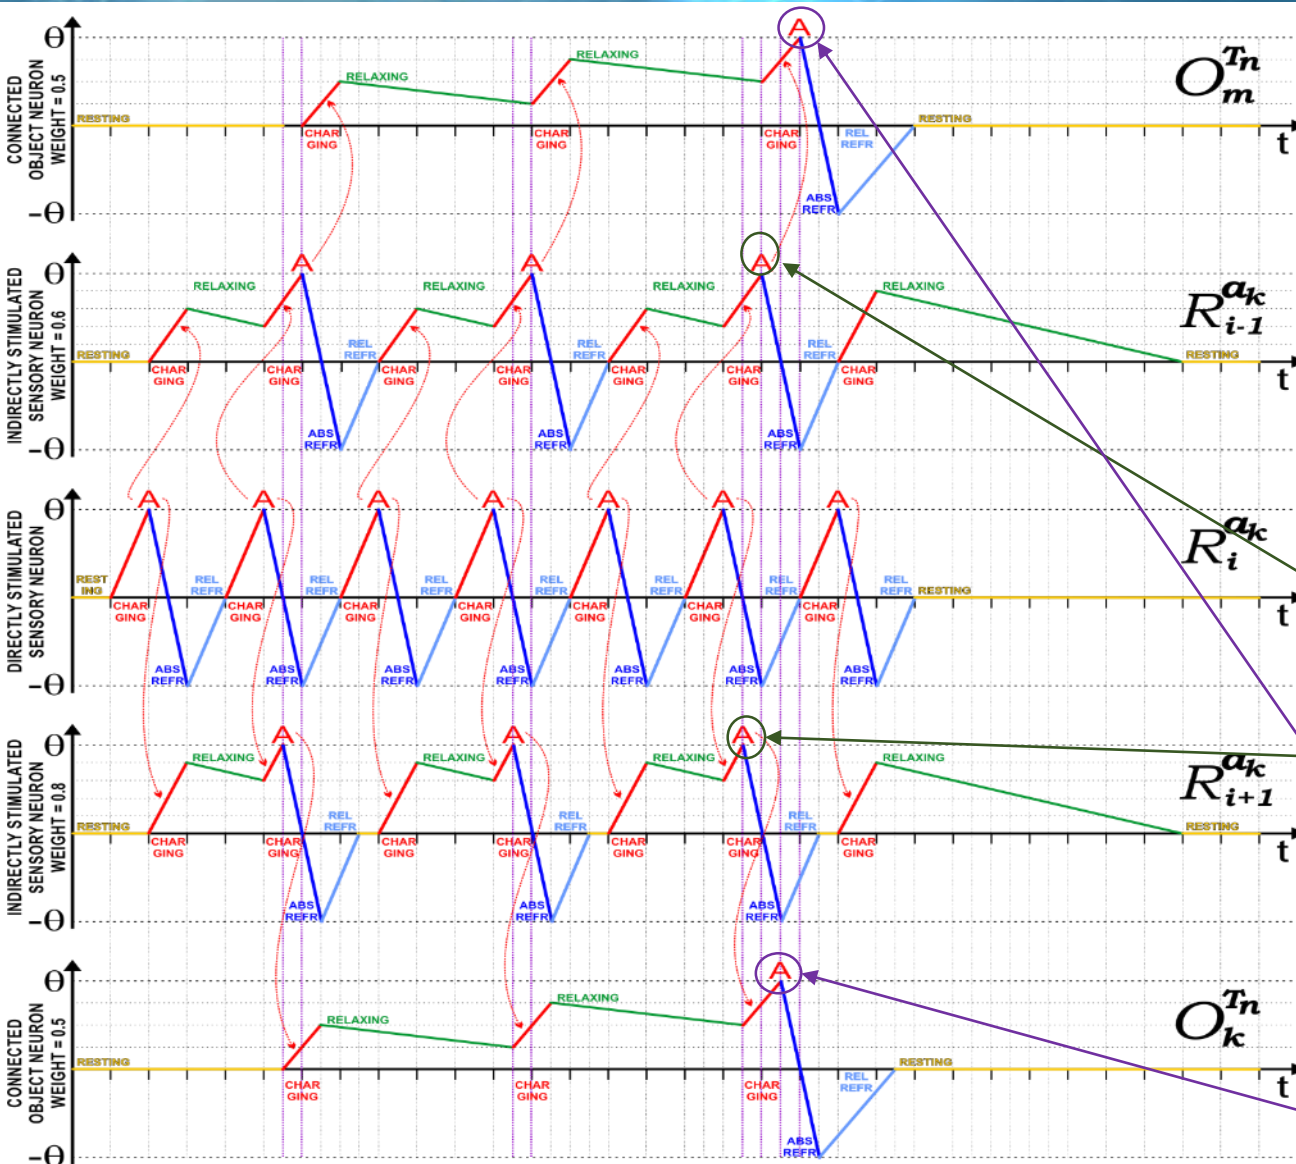
Jak Asocjacyjne Neurony Impulsowe pracują i wpływają na inne neurony?



Możemy zauważyć, iż neuron O_k wymaga **potrójnej stymulacji** przez neuron R_{i+1} i połączenie ważone wagą 0,5 żeby osiągnąć **próg aktywacji** $\theta = 1$.

Po zewnętrznej stymulacji lub po aktywacji (spike), procesy **relaksacji** lub **refrakcji** odpowiednio próbują przywrócić **stan spoczynku** neuronu.

Jak Asocjacyjne Neurony Impulsowe pracują i wpływają na inne neurony?



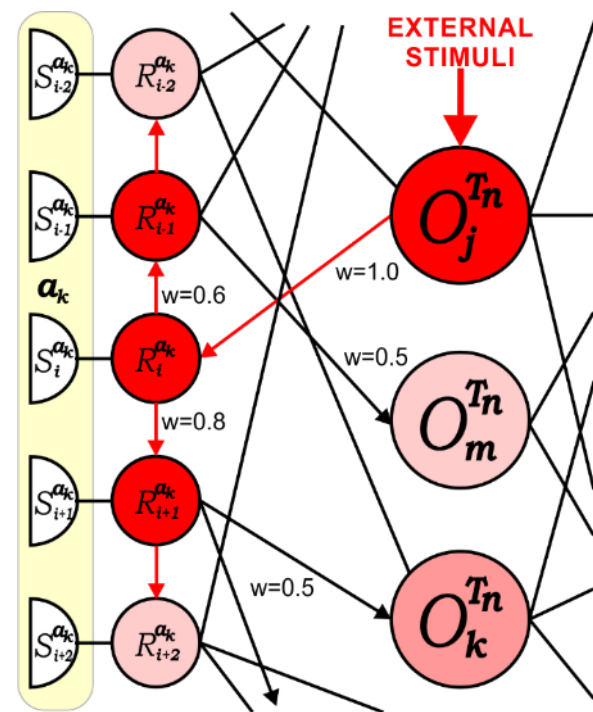

Neurony sensoryczne R_{i+1} and R_{i-1} są stymulowane z różną siłą zależną od wag połączeń (0,8 and 0,6) z neuronem R_i . To wywołuje **różny poziom ich pobudzenia** oraz **inne momenty aktywacji**. Neuron R_{i+1} osiąga próg aktywacji **wcześniej** niż neuron R_{i-1} , więc neuron R_{i+1} **szybciej** zaczyna stymulować neuron O_k niż neuron R_{i-1} rozpoczyna stymulację neuronu O_m . W taki sposób neuron O_k osiągnie aktywację **wcześniej** niż neuron O_m . To oznacza **większe podobieństwo** obiektu reprezentowanego przez neuron O_k niż przez neuron O_m . To jest zgodne z intuicją oraz realnym podobieństwem.


Jak Asocjacyjne Neurony Impulsowe pracują i wpływają na inne neurony?



To małe przesunięcie aktywacji w czasie dla neuronów O_k and O_m może wydawać się bez znaczenia, lecz jest ważnym fenomenem pracy **biologicznych sieci neuronowych** oraz **asocjacyjnych grafów neuronowych DASNG** decydującym **o stopniu i sile skojarzeń!**

Różnica w czasie aktywacji neuronów reprezentuje **slabsze lub mocniejsze asocjacje** z tymi obiektami, tutaj konkretnie **mniejsze lub większe podobieństwo** do nich. W taki sposób, **asocjacyjne neurony impulsowe** automatycznie **wnioskują**, wskazując ich różną siłę relacji z obiektami i danymi reprezentowanymi przez połączone bezpośrednio lub pośrednio neurony.





Wagi Połączeń Synaptycznych

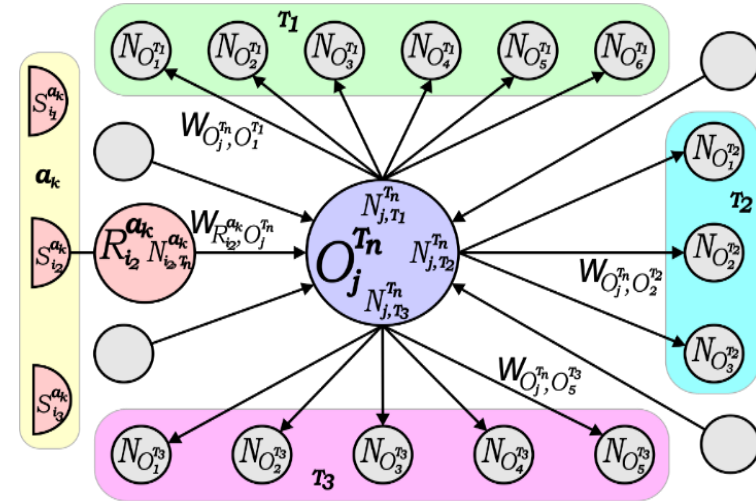


Neurony sensoryczne reprezentujące porządkowalne wartości są łączone z następującymi wagami odzwierciedlającymi podobieństwo reprezentowanych przez nie wartości:

$$W_{R_{v_i}^{a_k}, R_{v_j}^{a_k}} = 1 - \frac{|v_i^{a_k} - v_j^{a_k}|}{r^{a_k}}$$

Połączenia pomiędzy neuronami sensorycznymi i obiektów: :

$$W_{R_{v_i}^{a_k}, O_j^{T_n}} = \frac{1}{\|v_i^{a_k}\|} \quad W_{O_j^{T_n}, R_{v_i}^{a_k}} = \theta_{R_{v_i}^{a_k}} = 1$$



Wagi synaptyczne pomiędzy różnymi neuronami obiektów są wyznaczone na podstawie ilości obiektów, które definiują w strukturze DASNG w odniesieniu do pojedynczej tabeli (zbioru obiektów/rekordów/encji/krotek).


W pewnym uproszczeniu **jeśli neuron obiektu posiada M połączeń do obiektów reprezentowanych przez inną warstwę neuronów w sieci DASNG**, wagi przyjmują:


$$W_{O_j^{T_n}, O_k^{T_m}} = \frac{1}{N_{j, T_m}^{T_n}} \cong \frac{1}{M} \quad W_{O_k^{T_m}, O_j^{T_n}} = \frac{1}{N_{k, T_n}^{T_m}} \cong \frac{1}{N}$$

gdzie $N_{k, T_n}^{T_m} = N = 1$ dla relacji jeden-do-wielu (1:M) lub wiele-do-wielu (N:M).

Jeśli baza nie zawiera zduplikowanych obiektów, wtedy przybliżenie jest dokładne.

Przydatne jest więc zbudowanie oddzielnych list połączeń do każdej warstwy sieci DASNG w każdym neuronie w celu szybkiego wyznaczenia ilości połączonych neuronów M z daną warstwą lub wyznaczenia dokładnej ilości obiektów $N_{j, T_m}^{T_n}$.





Progi Aktywacji Neuronów



Progi aktywacji (spike/pulse) neuronów sensorycznych:

$$\theta_{R_{v_i}^{a_k}} = 1$$

Progi aktywacji (spike/pulse) neuronów obiektów:

$$\theta_{O_j^{T_n}} = \begin{cases} 1 & \text{if } \sum_{R_{v_i}^{a_k}} W_{R_{v_i}^{a_k}, O_j^{T_n}} \geq 1 \\ \sum_{R_{v_i}^{a_k}} W_{R_{v_i}^{a_k}, O_j^{T_n}} & \text{if } \sum_{R_{v_i}^{a_k}} W_{R_{v_i}^{a_k}, O_j^{T_n}} < 1 \end{cases}$$


Powyższa definicja progów aktywacji neuronów obiektów pozwala na aktywację neuronu poprzez całą kombinację definiującą dany neuron obiektu, tj. gdy jest on stymulowany przez cały zbiór definiujących go parametrów, ew. czasami również ich podzbiór, gdy jest on wystarczająco dyskryminatywny z punktu widzenia tego obiektu.

Brana jest więc pod uwagę unikalność i rzadkość cech definiujących poszczególne obiekty.


Linearna Aproksymacja Wewnętrznych Procesów Neuronowych



Asocjacyjne neurony impulsowe (ASN) w DASNG stosują **liniową aproksymację** wszystkich procesów. To znacząco upraszcza i przyspiesza obliczenia:



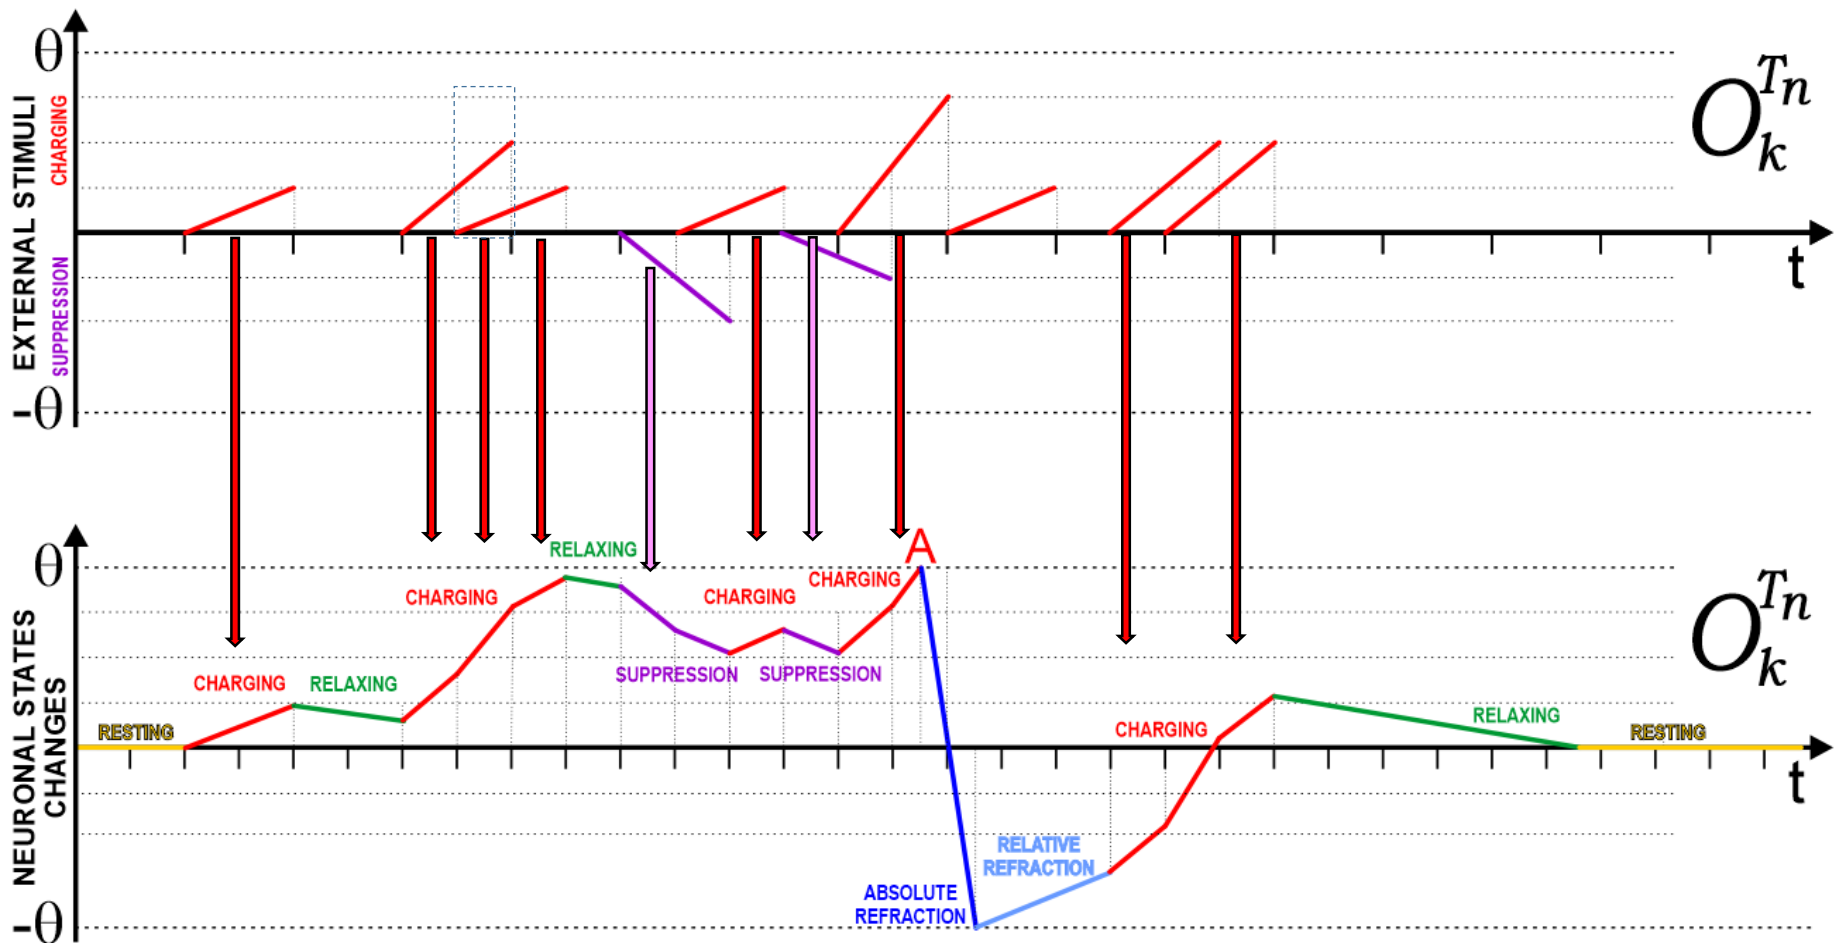
Każdy neuron tworzy swoją **wewnętrzną kolejkę procesów (IPQ)** uporządkowanych w czasie. Nowy proces dodawany jest do kolejki na podstawie stymulacji zewnętrznej neuronu dochodzącej od innego neuronu lub receptora. W celu odpowiedniego uporządkowania równoległych procesów wszystkich neuronów całej sieci DASNG w czasie stosowana jest **globalna kolejka zdarzeń (GEQ – Global Event Queue)**, której poszczególne zdarzenia śledzą momenty, w których poszczególne procesy w danych neuronach mają się rozpocząć wykonywać, kończąc tym samym poprzednie.



Tworzenie i Aktualizacja Wewnętrznej Kolejki Procesów



Wewnętrzna kolejka procesów (IPQ – Internal Process Queue) łączy ze sobą zewnętrzne stymulacje neuronu z istniejącymi wewnętrznymi procesami porządkując je chronologicznie w postaci kolejki rozłącznych w czasie procesów.

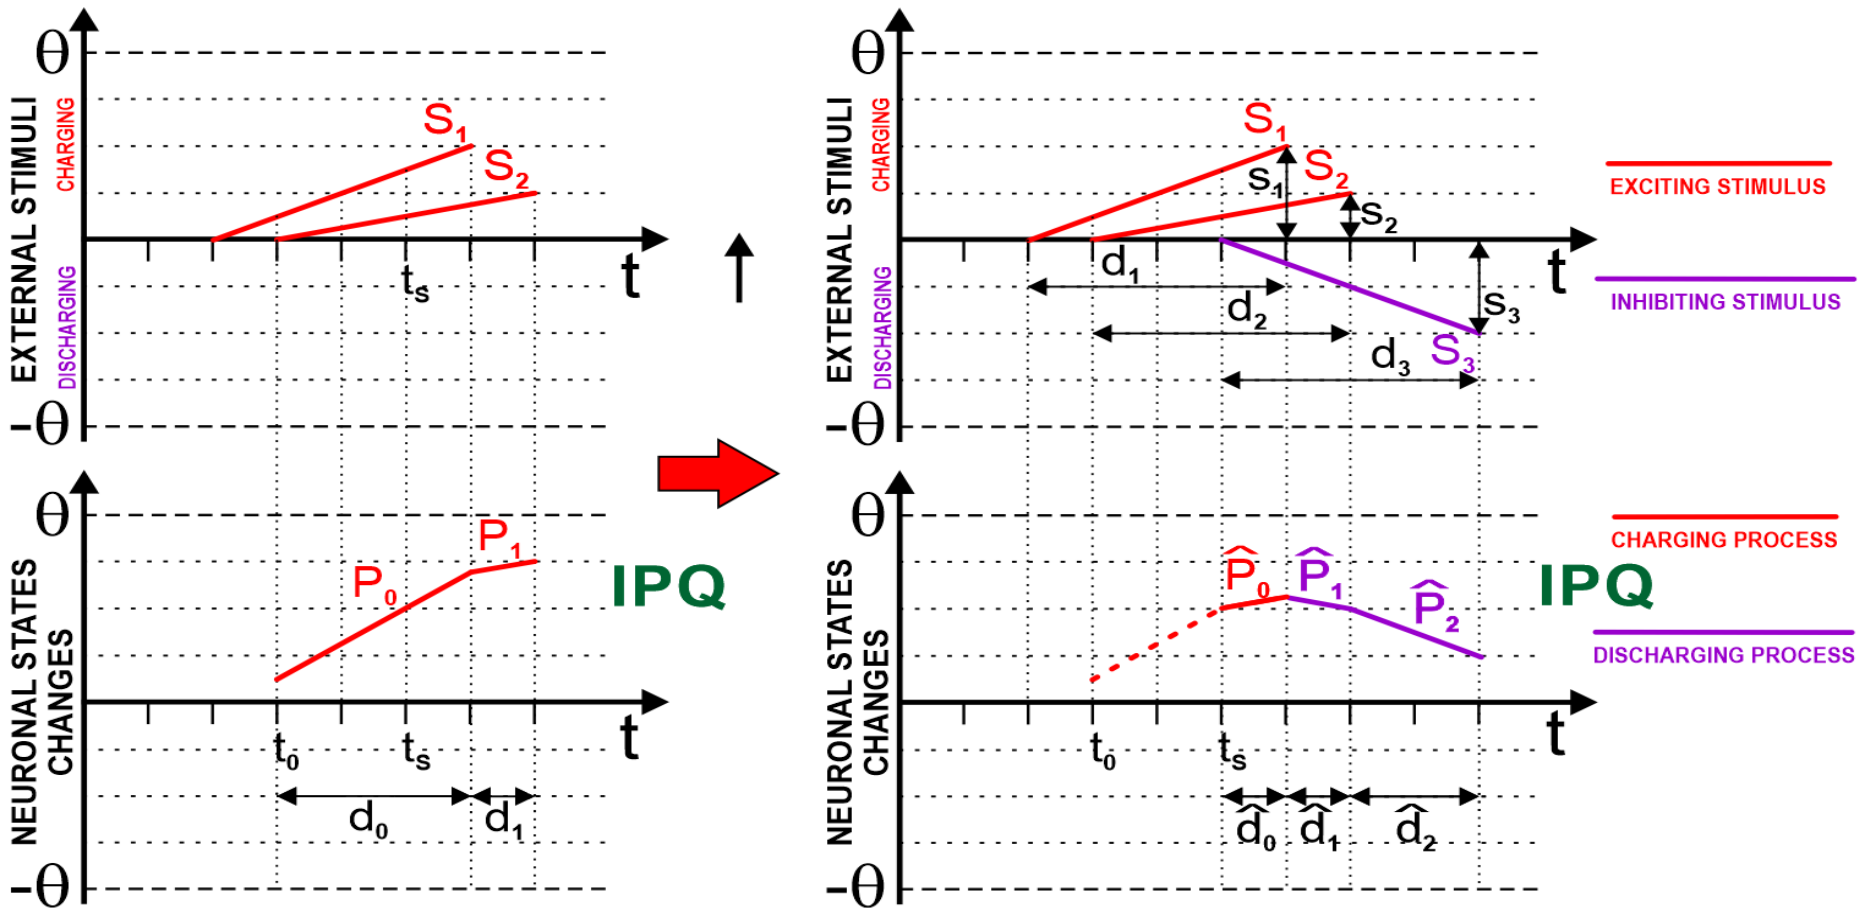



Łączenie Wewnętrznych Procesów z Pobudzeniami Synaptycznymi



$$\hat{P}_0 = (\hat{r}_0, t_s, d_0 - (t_s - t_0), s_0 \cdot \frac{d_0 - (t_s - t_0)}{d_0} + s_s \cdot \frac{d_0 - (t_s - t_0)}{d_s}, \hat{p}_0)$$

$$\hat{P}_1 = (\hat{r}_1, t_0 + d_0, d_s - (d_0 - (t_s - t_0)), s_s \cdot \frac{d_s - (d_0 - (t_s - t_0))}{d_s}, \hat{p}_1)$$

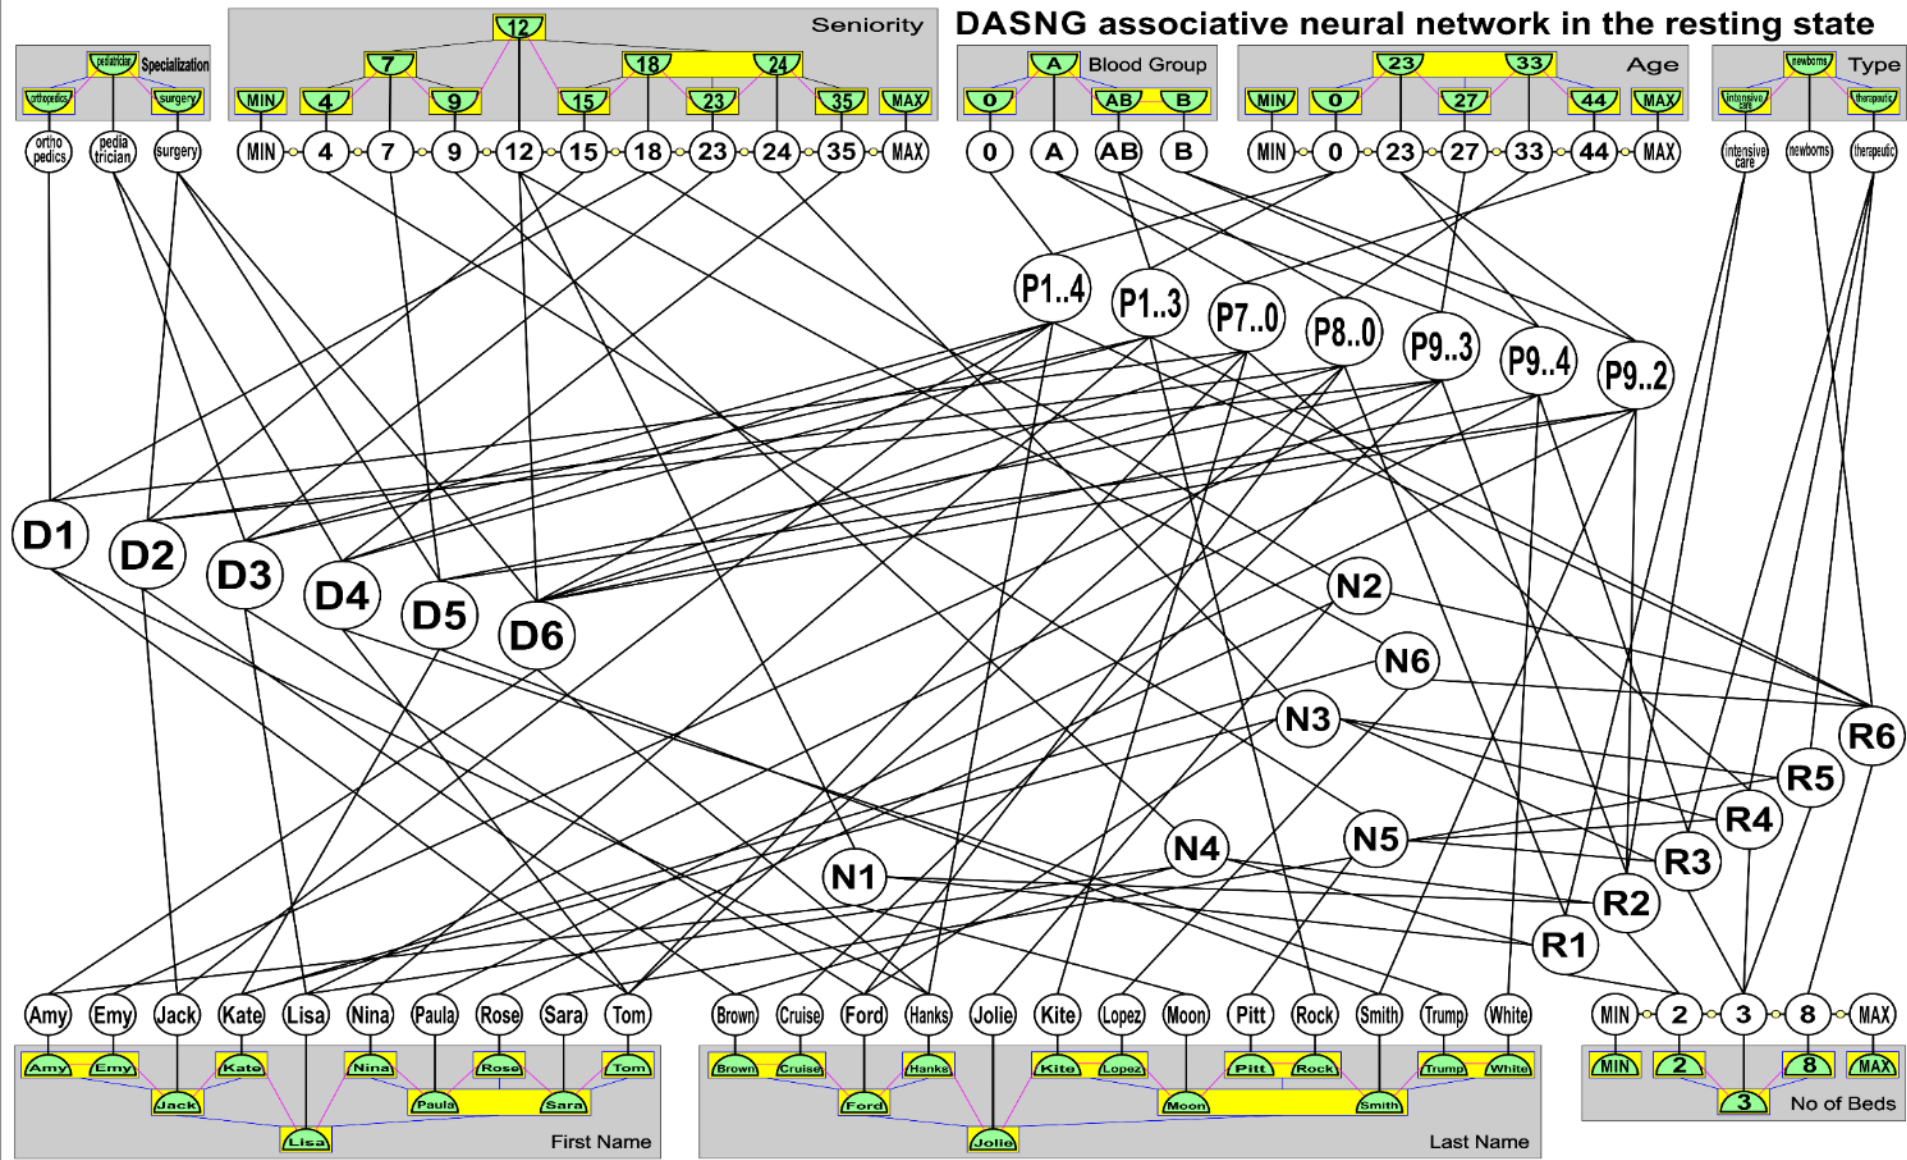





Wnioskowanie wykorzystujące DASNG



Neurony same zwracają wnioski po ich stymulacji przez receptory!

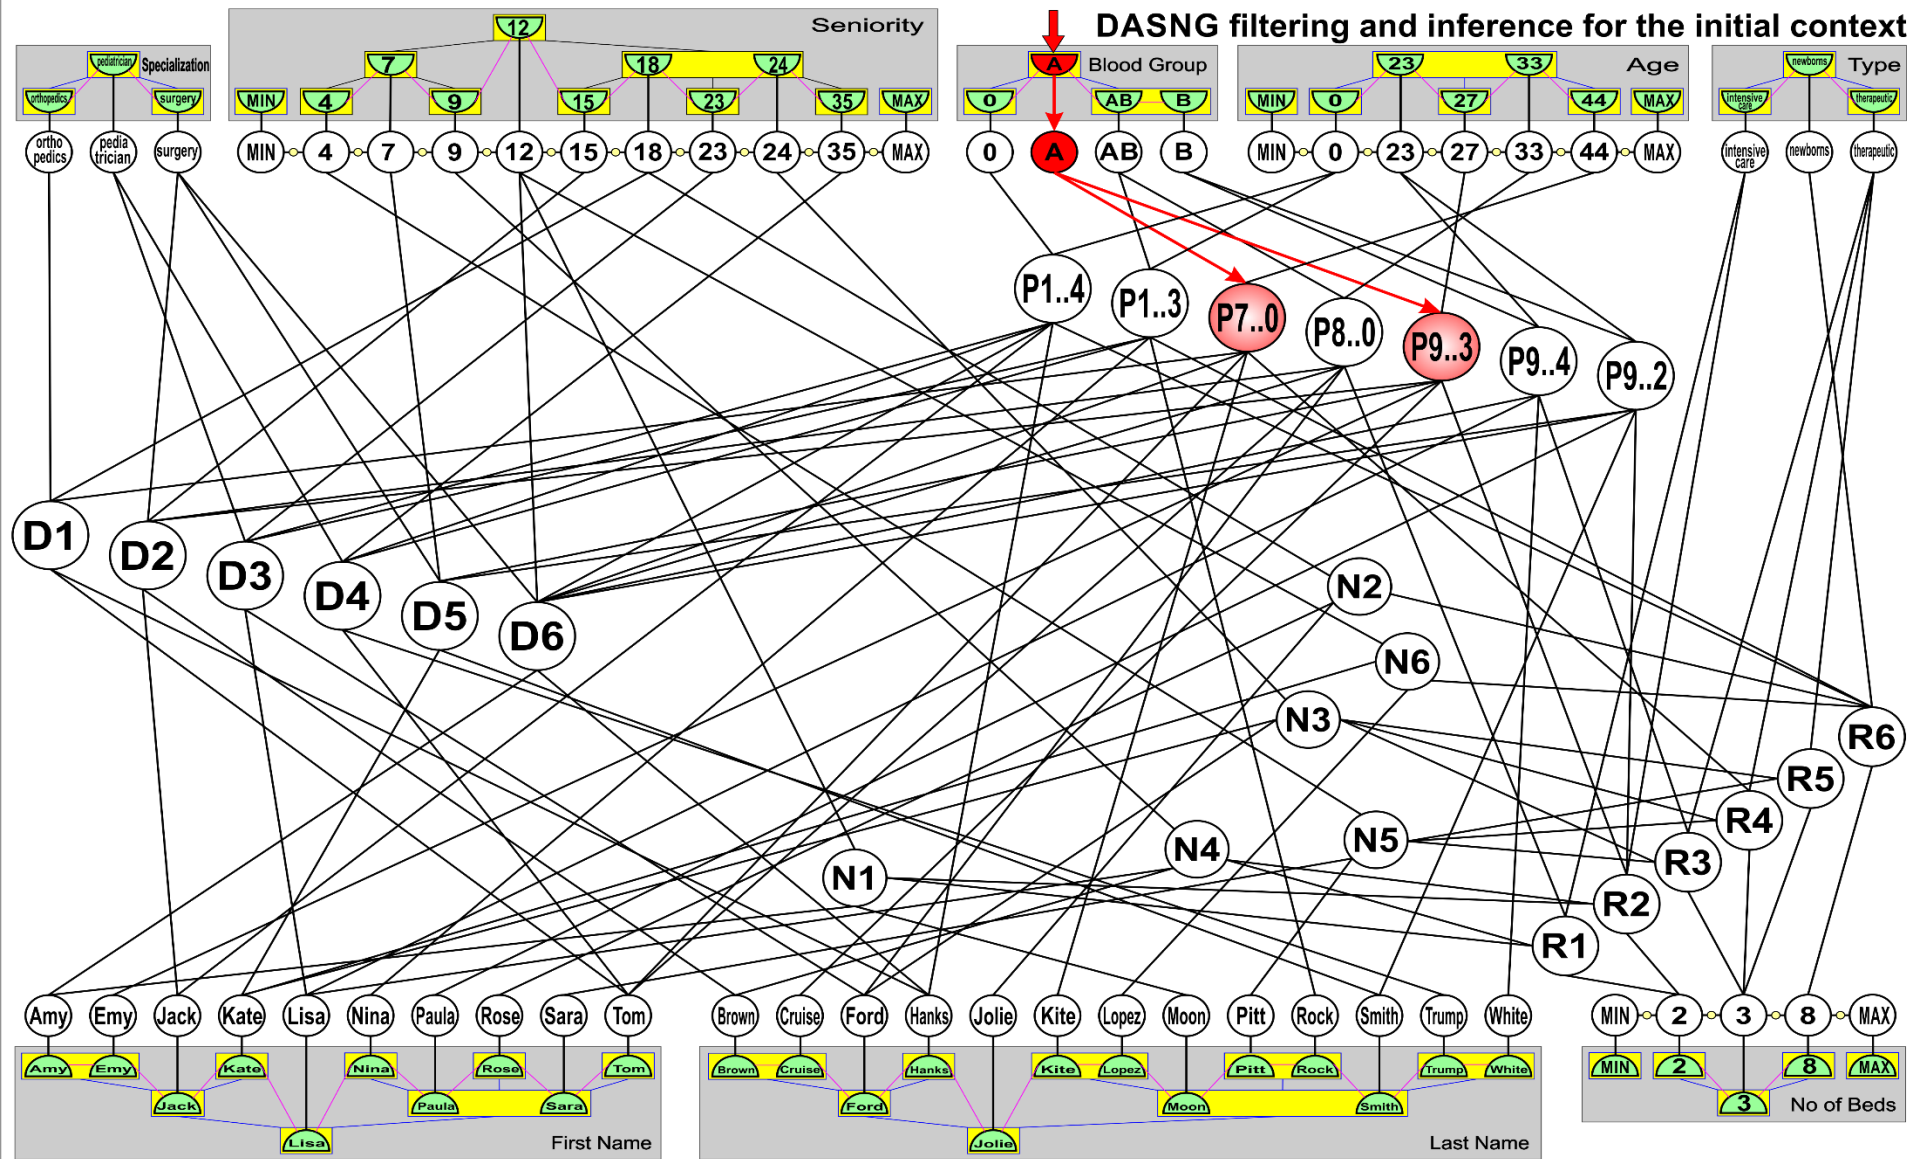





Wniosekowanie wykorzystujące DASNG



Szybki dostęp do informacji reprezentowanych przez aktywne neurony!

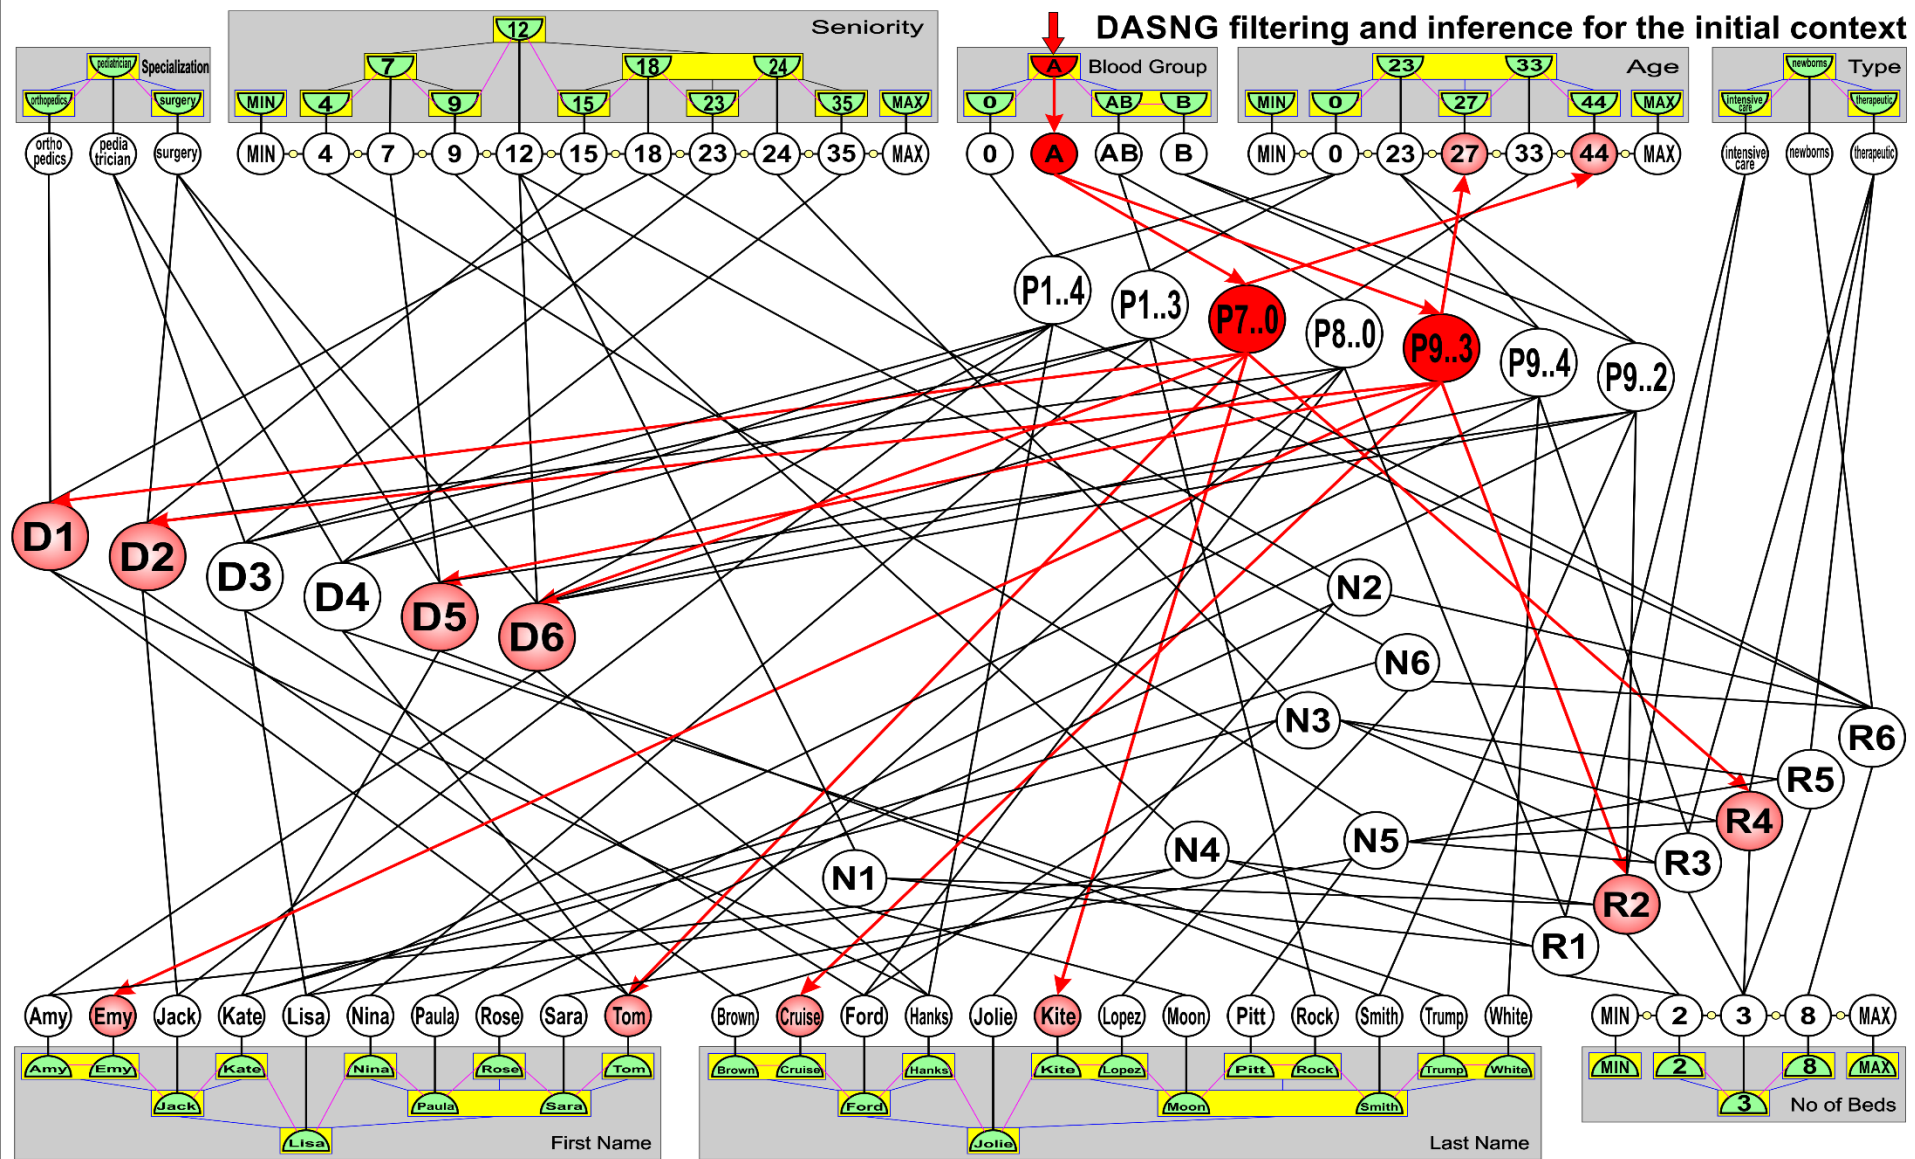





Wnioskowanie wykorzystujące DASNG



Połączenia reprezentujące asocjacje pozwalają na wnioskowanie!

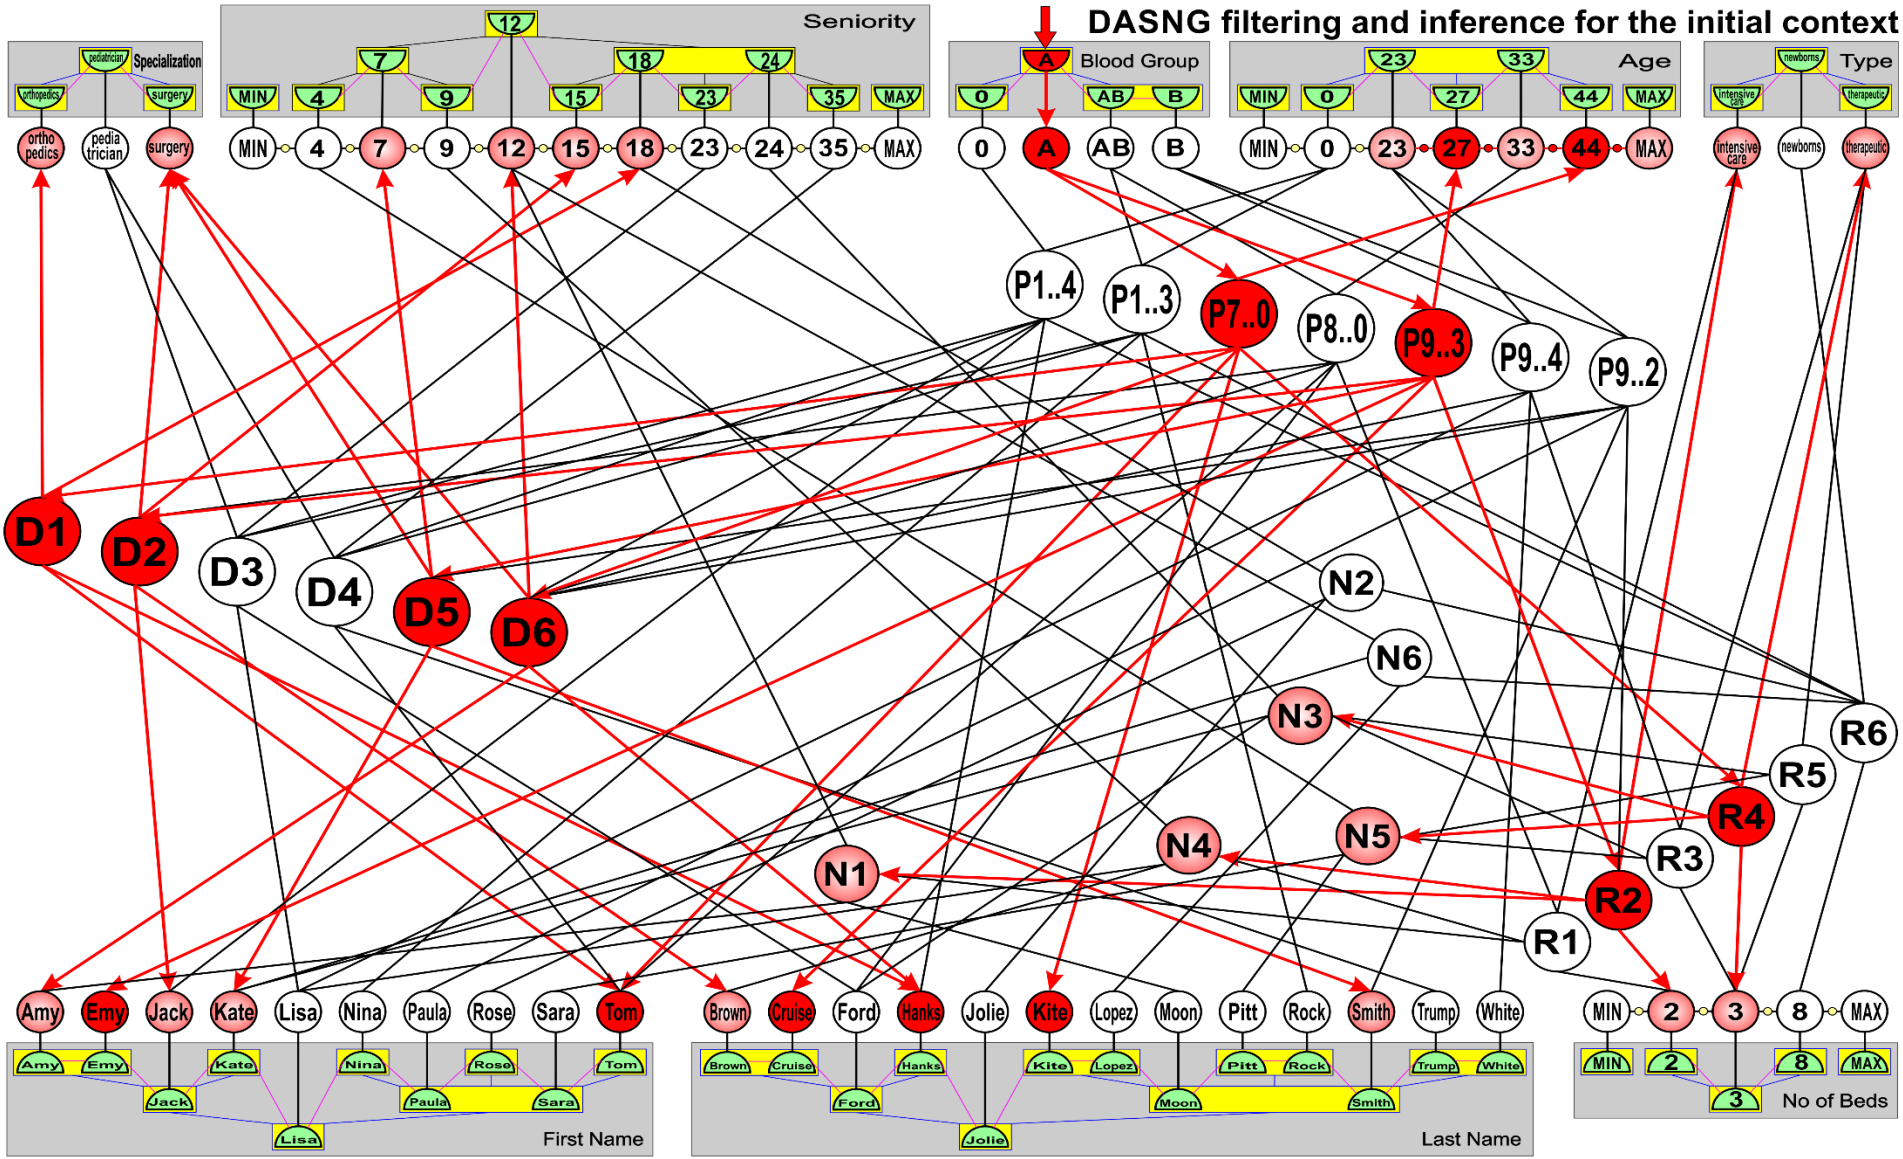




Wnioskowanie wykorzystujące DASNG



Pośrednio skojarzone informacje są również dostępne po chwili!





WNIOSKI



DEEP ASSOCIATIVE SEMANTIC NEURAL GRAPHS (DASNG) może służyć do:


- **transformacji baz danych** do reaktywnych asocjacyjnych struktur danych,
- **tworzenia głębokich sieci neuronowych** opartych o asocjacyjne neurony impulsowe i asocjacyjny model obliczeń i wnioskowania,
- **reprezentowania złożonych obiektów** kontekstowo jak w bazach danych, lecz dodatkowo również do **określenia specyficznej siły połączeń (asocjacji) pomiędzy powiązаныmi obiektami (encjami)**,
- **filtrowania wartości i obiektów (encji)** w zależności od inicjalnej stymulacji na wejściu sieci określonej kontekstem zapytania,
- szybko **zwracać posortowane obiekty** dla dowolnej kombinacji atrybutów,
- natychmiast **zwracać wartość minimum i maksimum** dowolnego atrybutu,
- **Wnioskować** na podstawie **inicjalnego kontekstu** wykorzystując stymulację sieci DASNG za pośrednictwem receptorów oraz neuronów sensorycznych,
- Tworzyć **system kognitywne** i sztucznej inteligencji oparte o wiedzę.

ZASTOSOWANIA



DEEP ASSOCIATIVE SEMANTIC NEURAL GRAPHS (DASNG)

planowane są do wykorzystania w CERNie
w **A Large Ion Collider Experiment (ALICE)**
w trakcie O2 i O3 uruchomień do kontroli jakości
oraz **Big Data** analizy w czasie rzeczywistym.



DASNG może być zrównoleglony w celu wyprowadzania wniosków
w czasie rzeczywistym (stałym).

Bibliografia i Literatura

1. **A. Horzyk**, J. A. Starzyk, J. Graham, Integration of Semantic and Episodic Memories, IEEE Transactions on Neural Networks and Learning Systems, 2017, [DOI: 10.1109/TNNLS.2017.2728203](https://doi.org/10.1109/TNNLS.2017.2728203).
2. **A. Horzyk** and J.A. Starzyk, Fast Neural Network Adaptation with Associative Pulsing Neurons, IEEE Xplore, In: 2017 IEEE Symposium Series on Computational Intelligence, 2017.
3. Basawaraj, Janusz A. Starzyk and **A. Horzyk**, Lumped Mini-Column Associative Knowledge Graphs, IEEE Xplore, In: 2017 IEEE Symposium Series on Computational Intelligence, 2017.
4. **A. Horzyk**, Deep Associative Semantic Neural Graphs for Knowledge Representation and Fast Data Exploration, Proc. of KEOD 2017, SCITEPRESS Digital Library, 2017.
5. **A. Horzyk**, Neurons Can Sort Data Efficiently, Proc. of ICAISC 2017, Springer-Verlag, LNAI, 2017, pp. 64-74, [ICAISC BEST PAPER AWARD 2017](#) 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. **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), DOI 10.1007/978-3-319-19090-7, Springer, Switzerland, 2016, 39-51.
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](#), 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. **Horzyk, A.**, How Does Generalization and Creativity Come into Being in Neural Associative Systems and How Does It Form Human-Like Knowledge?, Neurocomputing, 2014.
10. **Horzyk, A.**, Human-Like Knowledge Engineering, Generalization and Creativity in Artificial Neural Associative Systems, Springer, AISC 11156, 2014.



**Akademia Górniczo-
Hutnicza w Krakowie**

horzyk@agh.edu.pl

Google: [Horzyk](#)