

ARTYKUŁ POGLĄDOWY/REVIEW PAPER

Otrzymano/Submitted: 13.02.2013 • Zaakceptowano/Accepted: 18.02.2013

© Akademia Medycyny

Postrzeganie czasu przez człowieka: specyfika, modele i symulacje***Human timing: characteristics, models and simulations*****Maciej Komosinski¹, Adam Kups²**¹ Instytut Informatyki, Politechnika Poznańska² Instytut Psychologii, Uniwersytet im. Adama Mickiewicza w Poznaniu

Adam Kups

Streszczenie

Niniejszy artykuł poświęcony jest zagadnieniu postrzegania czasu trwania zdarzeń (ang. *timing*) przez człowieka. Zarysowano w nim bieżący stan wiedzy zwracając uwagę na niedostatek modeli, obejmujących szeroki zakres dziedzin, w których prowadzi się badania postrzegania czasu. Przedstawiono przykładową implementację popularnego modelu typu zegar–licznik w środowisku sztucznych sieci neuronowych. Opisano zjawisko „błędu porządku czasowego” oraz pokazano, jak zaproponowana sztuczna sieć neuronowa może naśladować zachowanie człowieka popełniając podobne błędy w zależności od parametrów opisujących działanie jej elementów składowych. Artykuł omawia też rolę technik symulacyjnych oraz metod sztucznej inteligencji i sztucznego życia w budowaniu działających i weryfikowalnych modeli niepoznanych jeszcze procesów i zjawisk biologicznych, których przykładem jest postrzeganie czasu. *Anestezjologia i Ratownictwo 2013; 7: 113-124.*

Słowa kluczowe: postrzeganie upływu czasu, sieć neuronowa, symulacja, błąd porządku czasowego, TOE

Abstract

This article reviews state of the art in the area of human timing and emphasizes the lack of models that would cover a wide range of disciplines where research on timing is carried out. A sample implementation of a clock-counter model in an artificial neural network is shown. The “time-order error” phenomenon is described and it is demonstrated that an artificial neural network, when appropriately tuned, can make similar errors and can mimic human behavior. The article also discusses the role of simulation techniques, artificial intelligence and artificial life in building of working, verifiable models of still unexplained biological processes and phenomena, an example of which is perception of time. *Anestezjologia i Ratownictwo 2013; 7: 113-124.*

Keywords: timing, neural network, simulation, time-order error, TOE

Wprowadzenie

Badania postrzegania czasu przez człowieka nie stanowią jednorodnego obszaru nauki. W literaturze przedmiotu odróżnia się m.in. postrzeganie czasu trwania zdarzeń lub bodźców (określane angielskim

słowem *timing*) od procesów regulacji aktywności okołodobowej (*circadian rhythms*) [1-3]. Niniejsza praca dotyczy tego pierwszego zagadnienia i pokazuje, w jaki sposób może funkcjonować mechanizm postrzegania czasu trwania bodźców, jak wygląda reprezentacja czasu i jakim zniekształceniom może

ulegać jego percepcja.

Badania nad postrzeganiem czasu trwania zdarzeń dotyczą zarówno zwierząt, jak i ludzi i wykorzystują niekiedy podobne paradygmaty badawcze. W prowadzonych od już dość dawna eksperymentach istotnym problemem jest ulotność przedmiotu badania: ludzie nie dysponują anatomicznymi receptorami czasu, a sama wielkość obserwowana jest względnie trudna do manipulacji eksperymentalnej. W rezultacie o naturze mechanizmu postrzegania upływu czasu można wnioskować jedynie w sposób pośredni, borykając się jednocześnie z tym, że struktury odpowiedzialne za przetwarzanie informacji czasowej same opierają się na informacji o charakterze czasowym (rozmaite kody neuronalne) [4]. Pomimo to, w literaturze można zetknąć się z dość sporą liczbą wyjaśnień pojedynczych zjawisk, a także ogólnych modeli wyjaśniających mechanizm przetwarzania informacji czasowej.

Istniejące modele [1,2,5] można podzielić na kilka kategorii: modele opierające się na procesach poznawczych (por. [6]), na rozmaitych mechanizmach zegara [7-10] czy też nowsze modele zmieniających się stanów w sieciach neuronowych [11,12]. Równoległe toczony są spory o to, czy mechanizmy postrzegania czasu są specyficzne (oparte na bazie specyficznych struktur neuronalnych i reprezentacji), czy niespecyficzne (związane z obszarami mózgu pełniącymi różne funkcje) [13]. Oprócz tego stawiane jest pytanie, czy te same mechanizmy są odpowiedzialne za postrzeganie czasu w różnych skalach [14-16]. Istniejący stan wiedzy – pomimo dość sporej liczby zgromadzonych eksperymentalnie danych – w tym neurobiologicznych [5,17,18] – daleki jest jeszcze od zaoferowania mocnej, ogólnej teorii, która integrowałaby dane zebrane przy pomocy różnych procedur eksperymentalnych z różnych dyscyplin (psychologii, psychofizyki, neuronauki, medycyny, etc.). Taka teoria powinna uchwycić fenomen postrzegania upływu czasu na wielu poziomach jednocześnie (na poziomie neuroanatomicznym, funkcjonalnym i subiektywnym), pokazując zależności między tymi poziomami. Niniejsza praca stanowi punkt wyjściowy do tworzenia modeli postrzegania upływu czasu, które łączyłyby wiedzę z różnych dyscyplin i pomagały zrozumieć sposób, w jaki przetwarzanie czasu rzeczywiście zachodzi.

Z uwagi na fakt, że ludzkie procesy poznawcze zachodzą w środowisku biologicznych sieci neuronalnych, adekwatnym jest tworzenie modeli tych procesów z wykorzystaniem sztucznych sieci neuronowych.

Nie jest to podejście konieczne w celu efektywnego opisu i wyjaśniania mechanizmów psychologicznych, w tym czasowych, otwiera jednak perspektywy do dialogu między neuronaukowym i psychologicznym poziomem opisu procesów myślowych człowieka. Tworzenie modelu neuronowego mechanizmu postrzegania upływu czasu przez człowieka nie jest również wolne od pewnych słabości, z których być może jedną z większych jest fakt, że do uproszczonego (wyidealizowanego) obrazu mechanizmów psychologicznych dokładany jest uproszczony obraz neuronów i połączeń między nimi. W zamian jednak język opisu sieci neuronowych oferuje pojęcia (takie jak np. przekazywanie i przetwarzanie informacji zakodowanej w sygnale czy też połączenia rekurencyjne), które usprawniają pracę teoretyczną i badawczą nad rozwijaniem teorii mechanizmów postrzegania upływu czasu.

Rola symulacji w badaniach biologicznych

Rozwijanie symulacyjnych modeli postrzegania czasu u człowieka służy dwóm celom. Po pierwsze, ma umożliwić lepsze zrozumienie mechanizmów przetwarzania czasu u człowieka, a co za tym idzie, pozwolić na diagnozowanie i leczenie różnych deficytów i dysfunkcji tych mechanizmów. Po drugie, może stanowić inspirację do tworzenia rozwiązań technicznych stosowanych w sztucznej inteligencji i robotyce, wpisując się w popularny nurt rozwijania algorytmów inspirowanych naturą. Oba wspomniane cele są przedmiotem zainteresowania interdyscyplinarnego obszaru badań nazywanego sztucznym życiem [19,20], zajmującego się budowaniem modeli wybranych zjawisk i procesów życiowych w różnych środowiskach: informatycznym (*software*) [21], sprzętowym (*hardware*) [22] oraz biochemicznym (*wetware*).

Modele symulacyjne można oczywiście stworzyć dla dobrze już poznanych zjawisk i procesów biologicznych, co pozwala na ich lepsze sformalizowanie lub zalgorytmizowanie, a w przypadku bardzo wiernych modeli – wykorzystanie ich do prowadzenia eksperymentów i do celów dydaktycznych. Jednak bardziej interesującym obszarem zastosowań są takie sytuacje, w których nie potrafimy za pomocą dostępnych środków poznać mechanizmów działania danego układu biologicznego; możemy jedynie obserwować efekty jego funkcjonowania oraz poddawać go działaniu określonych bodźców. Nie widząc budowy wewnętrznej badanego układu i nie rozumiejąc jego zasady działania, możemy – bazując na dostępnej

wiedzy, doświadczeniu, intuicji – konstruować modele rzeczywistego układu oraz starać się, by te modele jak najdokładniej oddawały jego zachowanie.

Trudności w poznaniu niektórych układów biologicznych wynikają nie tylko z ograniczeń technicznych (braku dostępności urządzeń i procedur pozwalających na zbadanie mechanizmów działania), ale również stąd, że wiele systemów biologicznych (genom, układ odpornościowy, mózg, organizm,...) składa się z olbrzymiej liczby prostszych elementów oddziałujących ze sobą w nieliniowy, skomplikowany, częściowo niedeterministyczny sposób. W takich sytuacjach globalne działanie układu jest efektem interakcji między tymi prostymi elementami i zawodzi tradycyjne podejście *top-down*, w którym badany układ (proces, zjawisko, mechanizm) rozkładamy na prostsze elementy, aż dojdziemy do podstawowych i zrozumiałych części składowych. Częściej wykorzystuje się wtedy podejście *bottom-up*, pozwalające na zbudowanie (zsyntetyzowanie) modelu badanego układu z prostszych elementów, a następnie jego symulowanie, poddawanie tym samym bodźcom co układ rzeczywisty, i sukcesywne ulepszanie aż do momentu, gdy model zachowuje się tak, jak układ rzeczywisty. Nie gwarantuje to oczywiście tego, że układ rzeczywisty jest faktycznie skonstruowany tak, jak stworzony model – jednak w obliczu opisanych trudności takie postępowanie stanowi nieocenioną (a często jedyną) metodę poznania zasady działania badanego procesu czy mechanizmu biologicznego. Z analogiczną sytuacją mamy do czynienia w przypadku badań mechanizmów postrzegania czasu u człowieka.

Model neuronowy mechanizmu postrzegania upływu czasu

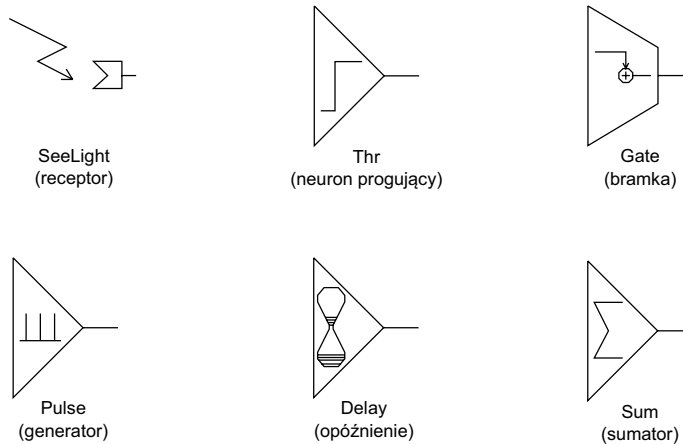
Celem naszej dotychczasowej pracy było stworzenie modelu postrzegania upływu czasu opartego na tradycyjnych (tzn. nie impulsowych) sztucznych sieciach neuronowych [23]. Za punkt wyjścia przyjęliśmy architekturę informacyjną modelu Skalarnego Postrzegania Upływu Czasu (*Scalar Timing Model* – STM) [7,24]. Pierwsza implementacja tej architektury opierała się na sztucznych neuronach, z których część odwoływała się do pewnych rozwiązań o charakterze bardziej technicznym niż biologicznym [25]. W kolejnych implementacjach [25,26] wykorzystywano już sztuczne neurony bardziej akceptowalne z biologicznego punktu widzenia, chociaż część pojedynczych sztucznych neuronów (np. neuron sumujący) odpowiada raczej

grupie neuronów biologicznych niż samodzielnemu neuronowi (rycina 1). Oprócz tego kolejne implementacje nastawione były również na wyjaśnianie zależności występujących w danych eksperymentalnych, dotyczących relacji między obiektywnym czasem trwania bodźca, a subiektywną reprezentacją tego czasu oraz względną zmiennością tych reprezentacji. Dodatkowo postanowiliśmy sprawdzić, na ile taka implementacja może odzwierciedlić i wyjaśnić dobrze udokumentowane zjawisko błędu porządku czasowego (*time-order error*). Równolegle prowadzone były prace nad usuwaniem różnego rodzaju artefaktów, które pojawiały się w tym dość skomplikowanym systemie przetwarzania informacji. Implementacje sztucznych sieci neuronowych oraz ich testy były prowadzone w środowisku symulacyjnym Framsticks [27].

Przedstawiona tu wersja sieci – którą nazywamy *Clock-Counter Timing Network* (CCTN, rycina 2) – składa się z szeregu modułów, z których część stanowi odzwierciedlenie komponentów zaproponowanych w oryginalnych pracach dotyczących STM [7,28]. Implementację w obecnym kształcie można uznać za model zaliczający się do klasy modeli generator-licznik. Dopiero przyjęcie określonych założeń dotyczących relacji między określonymi parametrami statystycznymi pomiarów a zakresem czasowym bodźców (tj. stały współczynnik zmienności pomiarów niezależnie od długości postrzeganych bodźców) sprawiłoby, że sieć neuronową można by pełnoprawnie określać realizacją STM. Poza modułami scharakteryzowanymi w teorii, istnieją również moduły CCTN służące temu, aby sieć mogła porównać pod względem czasu trwania dwa kolejno pojawiające się bodźce. Prezentowana implementacja stanowi więc ukonkretnienie wspomnianego modelu teoretycznego – model w swej ogólnej postaci nie tłumaczy wielu aspektów, na przykład tego, jak poszczególne moduły powracają do stanu początkowego po wykonaniu swoich zadań.


Struktura CCTN (rycina 2) składa się z 12 modułów:

- opisanych w architekturze STM:
 1. generator – generuje impulsy z określonym rozkładem odstępów między zdarzeniami (domyślnie wykorzystywany jest rozkład wykładniczy z parametrami dobranymi eksperymentalnie);
 2. przełącznik – w momencie pojawiania się bodźca umożliwia przesłanie impulsów do akumulatora;



Rycina 1. Rodzaje neuronów wykorzystane w sieci pokazanej w rycinie 2. Neuron typu „bramka” warunkowo (w zależności od stanu dodatkowego wejścia sterującego) przekazuje sygnał wejściowy na swoje wyjście. Nazwy pozostałych rodzajów neuronów określają sposób ich działania.

Figure 1. Neuron types used in the network shown in Figure 2. The “Gate” neuron conditionally passes input signal to output, depending on the state of the additional control input. The names of the remaining neurons indicate their function.



Rycina 2. Sztuczna sieć neuronowa porównująca czas trwania dwóch bodźców, oparta na architekturze STM. Opis modułów w tekście.

Figure 2. An artificial neural network based on the STM architecture; the network compares lengths of two stimuli. Individual modules are described in the text.

3. akumulator – gromadzi impulsy z generatora w trakcie trwania bodźca;
4. pamięć referencyjna – po zakończeniu pierwszego bodźca przechowuje informację o licz-

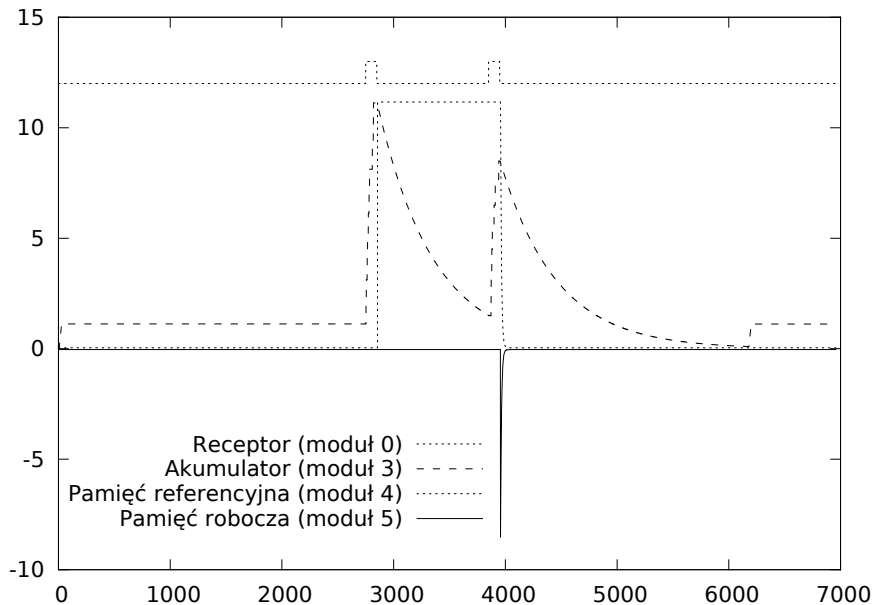
- bie impulsów zgromadzonych w akumulatorze;
5. pamięć robocza – po zakończeniu drugiego bodźca przechowuje informację o liczbie

- impulsów zgromadzonych w akumulatorze;
- 6. jednostka porównująca (komparator) – po zakończeniu drugiego bodźca porównuje zawartość pamięci referencyjnej i roboczej, wysyłając informację o tym, która pamięć przechowywała większą wartość (odpowiadająca czasowi trwania bodźca);
- dodanych do implementacji celem zapewnienia jej powtarzalnego działania i wyjaśnienia zjawiska TOE:
 - 7. moduł monitorujący pojawienie się bodźca;
 - 8. moduł sterujący modułami resetującym i progującym;
 - 9. moduł resetujący – oczyszcza akumulator do określonej wartości po zakończeniu trwania bodźca;
 - 10. moduł progujący – napełnia akumulator do określonej wartości podczas nieobecności bodźca;
 - 11. moduł pośredniczący – przesyła informację o zawartości akumulatora do pamięci referen-

cyjnej i roboczej;

- 12. moduł końca bodźca – przesyła informację o tym, że właśnie skończył się bodziec (sterującą modulem pośredniczącym i jednostką porównującą).

Na rycinie 3 widoczne są przebiegi sygnału w kluczowych neuronach sieci neuronowej podczas porównywania dwóch bodźców. Oba bodźce trwają obiektywnie tyle samo (100 kroków symulacyjnych), jednak generator w czasie pierwszego bodźca wygenerował więcej impulsów, i choć po procesie resetowania w akumulatorze pozostała większa wartość niż domyślnie (tzn. po naładowaniu przez moduł progujący), to wielkość tej rozbieżności nie zrównoważyła różnicy między ilościami zgromadzonych impulsów. W efekcie sieć uznała drugi bodziec za trwający krócej. Po zakończeniu trwania pary bodźców sieć wysłała ustalony sygnał informujący, który bodziec został rozpoznany jako dłuższy, i po określonym czasie wraca do stanu wyjściowego (przygotowuje się do porównania kolejnej pary).



Rycina 3. Wartości sygnałów w kluczowych neuronach wybranych modułów sieci porównującej dwa bodźce trwające po 100 kroków symulacyjnych. Górna linia kropkowana odpowiadająca receptorowi wykrywającemu dwa bodźce jest dla czytelności sztucznie podniesiona – faktycznie przebiega ona w zerze.

Figure 3. Signal value in key neurons of selected modules of the network that compares lengths of two stimuli lasting 100 simulation steps. The top dotted line that corresponds to the stimuli-detecting receptor has been moved up for clarity; it is actually located at zero.

Mając do dyspozycji tak przygotowaną sieć neuronową można zacząć wyprowadzać hipotezy o charakterze ilościowym i jakościowym dotyczące zachowania się człowieka w specyficznym kontekście funkcjonowania jego systemów poznawczych. Poza dostosowywaniem sieci do opisywanych w literaturze faktów, implementacja taka pozwala na własne predykcje tego jak zachowywałby się człowiek, gdyby niektóre z modułów mechanizmu przetwarzania informacji były w jakiś sposób zaburzone (np. uszkodzone lub działające w nietypowy sposób, wynikający ze zmiany standardowych wartości parametrów).

Błąd porządku czasowego

Błąd porządku czasowego (*time-order error* – TOE) stanowi dość dobrze udokumentowane zjawisko [29-35] wpływu czynnika kolejności prezentacji dwóch bodźców na sąd porównawczy dotyczący stosunku natężeń jakiejś cechy tych bodźców. W szczególności w modalności postrzegania czasu efekt ten przejawia się jako przeszacowanie (dodatni TOE) lub niedoszacowanie (ujemny TOE) czasu trwania pierwszego bodźca względem drugiego. Rozważmy dwa bodźce o różnych czasach trwania: dłuższym t_D i krótszym t_K , zatem $t_D > t_K$. Istnieją różne miary TOE, z których często stosowaną jest różnica między prawdopodobieństwem odpowiedzi badanego: „pierwszy bodziec trwał dłużej” – $P(D_1)$ – pod warunkiem, że tak jest faktycznie (najpierw zaszedł bodziec trwający t_D , a potem t_K), a prawdopodobieństwem odpowiedzi badanego, że „drugi bodziec trwał dłużej” – $P(D_2)$, pod warunkiem, że tak rzeczywiście jest (najpierw zaprezentowano bodziec trwający t_K , a potem t_D). Jest to zatem różnica prawdopodobieństw warunkowych: $TOE = P(D_1|t_D, t_K) - P(D_2|t_K, t_D)$. W przypadku, gdy w eksperymencie badany porównuje dwa bodźce równej długości t , TOE wyznacza się jako $P(D_1|t, t) - \frac{1}{2}$. W badaniach nad postrzeganiem czasu wyłoniono szereg czynników wpływających na TOE [36-39], z których wielokrotnie potwierdzonym jest wpływ czasu trwania bodźców: im dłużej trwające bodźce badany porównuje, tym bardziej ujemne wartości TOE są obserwowane. Gdy bodźce są krótkie, TOE jest dodatnie.

Powstało jak dotąd kilka wyjaśnień tego zjawiska [29,40], z których żadne nie jest całkowite i wolne od wad. Wśród wyjaśnień TOE można wyróżnić wyjaśnienia jakościowe (odpowiadające na pytanie o naturę mechanizmu odpowiadającego za powstanie

tego fenomenu) i ilościowe (starające się określić ściśle zależności między parametrami bodźców a wielkością i znakiem TOE). Niewiele wyjaśnień stanowi syntezę obu tych podejść, łącząc zalety intuicyjnego opisu mechanizmu ze szczegółowymi przewidywaniami ilościowymi (por. [10]). Brak jest zatem wyjaśnień stanowiących solidną teorię tego zjawiska. Wychodząc naprzeciw potrzebie stworzenia takiej teorii proponujemy implementacje opartą na architekturze STM [7,28] rozwiniętą w taki sposób, aby przy jej pomocy można było wyjaśniać i przewidywać zjawisko TOE.

Zjawisko TOE pojawia się w naszej implementacji w związku z interakcją działań dwóch modułów sieci: modułu ładującego akumulator do pewnej stałej wartości progowej (modułu progującego) oraz modułu oczyszczającego akumulator po pojawieniu się bodźca (modułu resetującego). Akumulator to moduł składowy architektury informacyjnej STM, który zbiera informacje o liczbie impulsów emitowanej przez inny moduł – generator impulsów – w trakcie trwania bodźca. Liczba impulsów stanowi informację o czasie trwania bodźca, która po zakończeniu trwania bodźca jest przesyłana do pamięci roboczej. Bardziej szczegółowy opis tego mechanizmu można znaleźć w [7], a także w [26].

Dodatnie TOE wynika zatem z niedostatecznie szybkiego naładowania akumulatora do wartości progowej po jego oczyszczeniu się, po ekspozycji pierwszego bodźca z pary – impulsy pojawiające się w akumulatorze muszą więc najpierw wyrównać jego stan do wartości progowej, zatem jest większa szansa na to, że drugi bodziec zostanie uznany za krótszy. Zjawisko ujemnego TOE wynika z niedostatecznie szybkiego oczyszczenia się akumulatora przed pojawieniem się drugiego bodźca w parze (w akumulatorze w momencie pojawienia się drugiego bodźca znajdują się więc nadprogramowe impulsy przekraczające wartość progową – istnieje zatem większa szansa, że drugi bodziec będzie się wydawał dłuższy).

Ponieważ w naszej implementacji generator emituje impulsy zgodnie z rozkładem Poissona, badania TOE dotyczące poszczególnych par bodźców należy powtarzać wielokrotnie, by zmniejszyć efekty niedeterminizmu generatora i odkryć prawidłowości w zachowaniu sieci neuronowej. Aby zilustrować badanie zjawiska TOE przy pomocy narzędzi symulacyjnych, postanowiliśmy postawić sieć przed zadaniem porównywania 1500 par bodźców (150 razy 10 różnych par), tak jak miało to miejsce w eksperymencie Allan


[30]. Należy pamiętać, że jednostką czasu w eksperymentach symulacyjnych jest krok symulacyjny odpowiadający jednej milisekundzie czasu rzeczywistego. Jedną z głównych różnic między eksperymentem Allan a zadaniem postawionym opisywanej sieci jest fakt, że w eksperymencie na ludziach bodźce były pogrupowane w 5 sesjach po 3 bloki po 10 powtórzeń każdej pary w losowej kolejności, podczas gdy sieć porównywała ciągiem 1500 par bodźców (również w losowej kolejności – ale każda z rozważanych sieci w tej samej). Po zakończeniu eksperymentów dla każdej pary bodźców została wyliczona częstość odpowiedzi „pierwszy bodziec był dłuższy”, a następnie wyznaczono wartość TOE.

Oprócz prostej demonstracji zjawiska TOE, postanowiliśmy dopasować wybrane parametry sieci tak, aby uzyskać jak największą zgodność wyników z wynikami wybranego badanego – BJ – przedstawionymi w eksperymencie II z artykułu Allan [30]. Za miarę zgodności przyjęliśmy wielkość błędu średniokwadratowego MSE (którą minimalizowaliśmy) między wynikami sieci dla poszczególnych prawdopodobieństw, a wynikami badanego BJ. Manipulowaliśmy czterema parametrami: wielkością wartości domyślnej w akumulatorze (ang. *bias*), tempem ładowania akumulatora do wartości domyślnej (*bias reload rate*), tempem generowania impulsów (*pacemaker period*) i tempem resetowania akumulatora (*accumulator reset rate*). Zachowanie sieci było zatem determinowane przez te cztery wartości; pokazane dalej wykresy prezentują przekroje dwu-

wymiarowe przez czterowymiarową przestrzeń – dwa parametry są ustalone, a dwa się zmieniają.

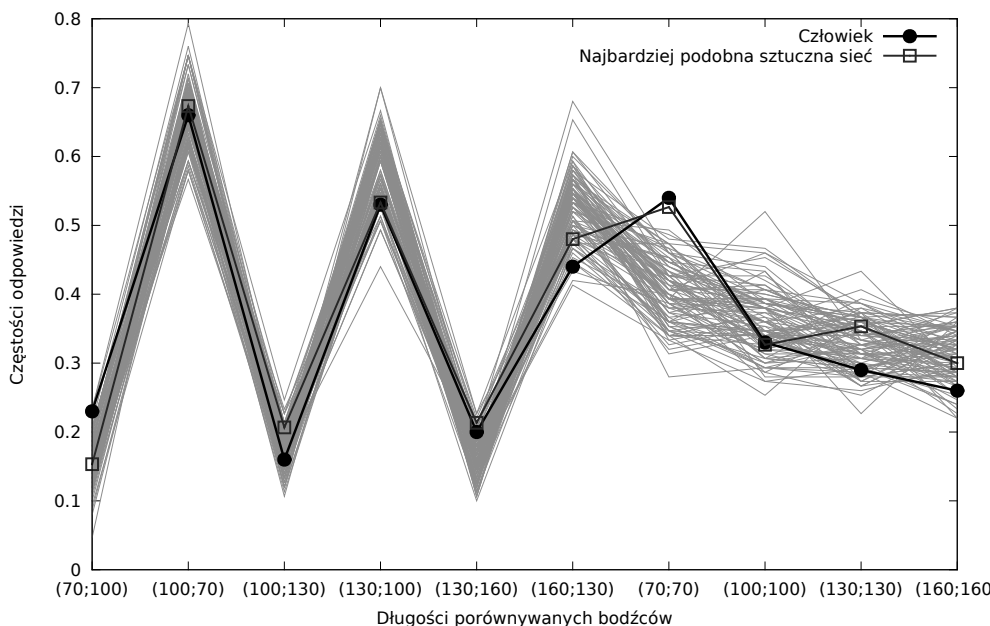
Rycina 4 pokazuje zależność błędu średniokwadratowego MSE – stanowiącego miarę dopasowania zachowania sieci do zachowania badanego BJ – od opisanych powyżej parametrów sieci neuronowej. Wykresy uwiadcniają pewne prawidłowości: sieci neuronowe z niższym tempem resetowania akumulatora (*reset rate* = 0.0016) i wyższym tempem generowania impulsów (jeden impuls na 10 kroków symulacyjnych) obarczone są mniejszym błędem niż sieci z wyższym tempem resetowania (*reset rate* = 0.002) i niższym tempem generowania impulsów (jeden impuls co 20 kroków symulacyjnych).

Interpretacja tych wyników jest w miarę klarowna – ponieważ znacząca większość wyników BJ charakteryzuje się ujemnym TOE, sieć neuronowa, która w tym zakresie czasów trwania bodźców będzie przeszacowywała drugi bodziec względem pierwszego (wysokie tempo generowania impulsów, wolne tempo resetowania) będzie charakteryzowała się ujemnym TOE, zatem szansa na podobne zachowanie się człowieka i takiej sieci będzie większa. W szczególności można zauważyć, że gdy akumulator resetuje się wolno (lewy wykres), wartość domyślna w akumulatorze i tempo ładowania akumulatora nie mają większego wpływu na MSE – przynajmniej w pokazanym zakresie wartości. Dokładniejsza analiza ujawnionych trendów może pozwolić na dogłębne zrozumienie tego, jak określone wartości przedstawionych parametrów przekładają się



Rycina 4. Zależność błędu średniokwadratowego sieci (MSE) od wielkości wartości domyślnej w akumulatorze (*bias*) i od tempa ładowania akumulatora do wartości domyślnej (*bias reload rate*). Po lewej: tempo generowania impulsów = 10 i tempo resetowania akumulatora = 0.0016. Po prawej: tempo generowania impulsów = 20 i tempo resetowania akumulatora = 0.002.

Figure 4. Mean square error (MSE) for different accumulator bias values and bias reload rates. Left: pacemaker period = 10 and accumulator reset rate = 0.0016. Right: pacemaker period = 20 and accumulator reset rate = 0.002.



Rycina 5. Częstości odpowiedzi „pierwszy bodziec dłuższy” osiągnięte przez sieci neuronowe najlepiej dopasowane do badanego BJ oraz przez niego samego.

Figure 5. Frequencies of the “first stimulus has been longer” answer provided by neural networks that best simulate the subject, BJ, and provided by BJ themselves.

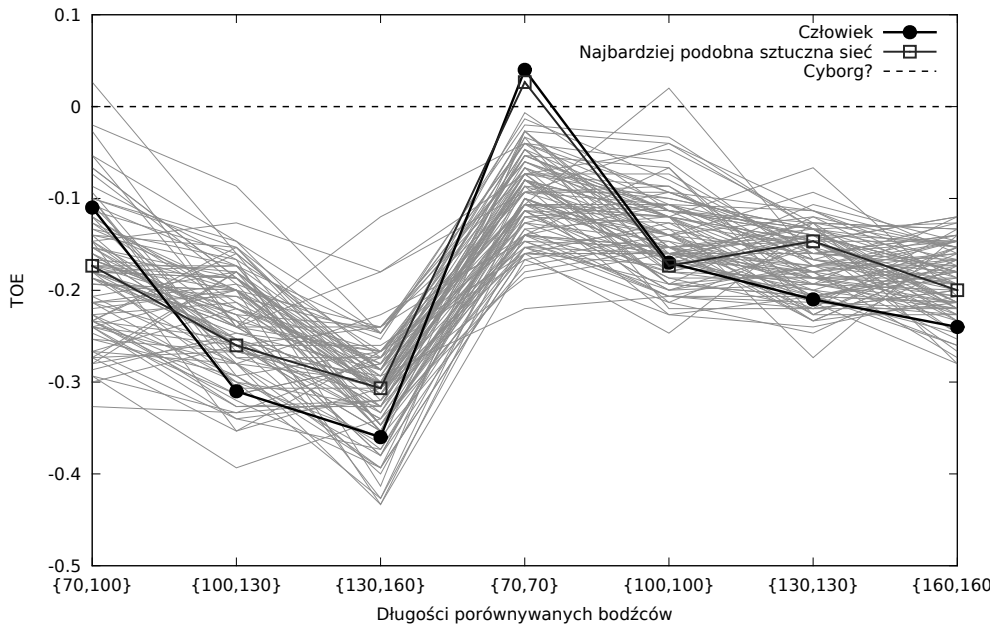
na funkcjonowanie poznawcze człowieka.

Ryciny 5 i 6 pokazują odpowiednio wartości prawdopodobieństw odpowiedzi „pierwszy bodziec dłuższy” i wartości TOE dla różnych typów par bodźców. Poszczególne linie odpowiadają zachowaniu sieci neuronowych dla wszystkich wartości parametrów wykorzystanych po lewej stronie ryciny 4; jedna z linii ilustruje zachowanie badanego BJ. Jak widać, zachowania wybranych sztucznych sieci neuronowych są podobne do wyników badanego. Na rycinie 6 przedstawiono również sytuację, w której TOE wynosi zero, a więc błąd porządku czasowego nie zachodzi. Należy pamiętać, że z uwagi na charakter miary, jaką przyjęto do obliczenia TOE, jej zerowa wartość nie oznacza, iż badany lub sieć dokonywali zawsze trafnych osądów. TOE równe zero oznacza jedynie, że żaden z bodźców w parze nie był przyszacowywany względem drugiego – wystarczy, że badany myli się tak samo często dla obu kolejności bodźców o różnej długości, a dla równo długich bodźców, odpowiedzi badanego nie faworyzują żadnego z nich.

W pewnych sytuacjach – np. gdy naszym celem jest analiza patologii w działaniu systemów poznawczych powiązanych z postrzeganiem czasu trwania bodź-


ców – jeszcze lepszym narzędziem pracy teoretycznej jest analiza wpływu parametrów sieci na podobieństwo zachowania sieci do zachowania człowieka. Po znalezieniu zestawu parametrów względnie dobrze dopasowującego sieć do wyników empirycznych, można przeprowadzać analizy pokazujące jak zmieni się zachowanie sieci, jeśli wartości parametrów będą modyfikowane lub jeśli zmianie ulegnie część całej architektury. W szczególnym przypadku, gdy parametry lub moduły sieci mają właściwą interpretację empiryczną, można na tej podstawie wyprowadzać predykcję zachowania człowieka poddanego różnego rodzaju wpływowi (środków farmakologicznych, stresu, choroby, itp.).

W celu zbadania, w jaki sposób zmiana wartości parametrów sieci wpływa na wielkość TOE dla bodźców trwających 70 i 100 kroków symulacyjnych, przeprowadzono dodatkową analizę rezultatów uzyskanych w opisanym powyżej eksperymencie. Rycina 7 pokazuje, że przy ustalonym tempie resetowania akumulatora, w miarę jak zwiększa się wartość domyślna w nim zawarta, TOE staje się coraz bardziej dodatni, dążąc do wartości charakteryzującej badanego BJ. TOE rośnie w tej sytuacji, gdyż wartość domyślna



Rycina 6. Wartości TOE osiągnięte przez sieci neuronowe najlepiej dopasowane do badanego BJ oraz przez niego samego. Przerwana linia pokazuje hipotetyczną sytuację, w której TOE wynosi zero.

Figure 6. The TOE values provided by neural networks that best simulate the subject, BJ, and provided by BJ themselves. The dashed line illustrates a hypothetical situation for zero TOE.



Rycina 7. Wykres obrazujący zmianę wartości błędu porządku czasowego dla bodźców trwających 70 i 100 kroków symulacyjnych w sieci o tempie generowania impulsów równym 10 i tempie resetowania akumulatora równym 0.0016, w zależności od wielkości wartości domyślnej w akumulatorze (*bias*) i od tempa ładowania akumulatora do wartości domyślnej (*bias rate*).

Figure 7. Illustration of the time order error values of a CCTN with pacemaker period = 10 and accumulator reset rate = 0.0016. The network compared two stimuli lasting 70 and 100 simulation steps.

ma jednocześnie mały wpływ na czas resetowania się akumulatora, a z drugiej strony rośnie jej stosunek do wartości, która zostaje w akumulatorze po resetowaniu. Powoduje to, że szansa uznania pierwszego bodźca za dłuższy wzrasta (choć ogólna tendencja cały czas sprowadza się do przeszacowywania drugiego bodźca). Na rycinie widać również, że prawie żadnego wpływu na wyniki nie ma tempo ładowania się akumulatora do wartości domyślnej – jest ono prawdopodobnie zbyt duże w sprawdzanym zakresie lub proces ten w ogóle nie zachodzi w interwale między dwoma bodźcami. Ta analiza potwierdza, że wykorzystane narzędzia eksperymentalne i sztuczna sieć neuronowa pozwalają znacząco ułatwić wyjaśnienie i zrozumienie efektu TOE, a także pozwalają na znalezienie zestawu parametrów prowadzącego do określonej wartości TOE.

Podsumowanie

Przedstawione wyniki stanowią ilustrację wykorzystania technik sztucznej inteligencji i sztucznego życia do wyjaśniania mechanizmów ludzkiego postrzegania czasu. W zaprezentowanych eksperymentach ujawnia się kilka zalet podejścia implementacyjno-symulacyjnego. Wyniki symulacyjne wskazują na to, jaki zestaw parametrów sieci neuronowej pozwala na przybliżone wyjaśnienie zjawiska TOE. Parametry te nie są abstrakcyjne – mają one swoją ścisłą interpretację funkcjonalną w ramach modelu typu zegar-licznik. Oprócz samego wyjaśniania zjawiska TOE, wyniki pokazują, w jaki sposób zachowanie sieci może się zmieniać w przypadkach, gdy parametry przyjmują inne niż wynikające z dopasowania wartości. Taką sytuację można traktować jako obserwację pewnych stanów patologicznych sieci i rozważyć, czy analogiczne, niepożądane wzorce nie pojawiają się też u ludzi. Niezwykle interesująca jest możliwość postawienia sztucznej sieci neuronowej przed sytuacją eksperymentalną zbliżoną do tej, z którą miała do czynienia osoba badana. Pozwala to na bardziej jednoznaczne interpretowanie wyników, a więc uniknięcie lub ograniczenie rozumowań przez analogię oraz używania metafor w trakcie pracy badawczej.

Pomimo osiągniętego ukonkretnienia modelu, jakim jest przedstawiona sztuczna sieć neuronowa

a także jej elementy składowe, stanowi ona ciągle pewne uproszczenie ludzkiego mechanizmu postrzegania czasu. Jest to typowa cecha każdego modelu; aby model mógł być jak najbardziej użyteczny, należy w jak najszerszym zakresie prowadzić proces falsyfikacyjny – a więc przeprowadzać jak najwięcej eksperymentów celem sprawdzenia, w jakim zakresie założenia co do konstrukcji sieci pozostają słuszne.

Zaprezentowane tu eksperymenty dotyczyły jedynie zjawiska TOE, a więc pewnego fenomenu, które – mimo iż nazywane jest błędem – tkwi jednak w ludzkiej naturze. Eksperymenty, które można przeprowadzać przy pomocy naszej implementacji lub jej kolejnych wersji i modyfikacji nie ograniczają się jednak tylko do domeny czystej psychologii poznawczej czy też psychofizyki postrzegania czasu. W literaturze znane są raporty z badań nad mechanizmami postrzegania czasu u osób, u których stymulowano zakręt nadbrzeżny przezczaszkową stymulacją magnetyczną – TMS [41], u osób ze stwierdzoną depresją [42] czy u osób chorych na chorobę Parkinsona [43-48]. Nowe eksperymenty symulacyjne przy odpowiednio zmodyfikowanej sieci – które w związku z danymi z cytowanych wyżej badań można przeprowadzić – mogą pozwolić zweryfikować przyjęte założenia o architekturze sieci, przyczynić się do znalezienia bardziej ścisłego wyjaśnienia mechanizmów postrzegania upływu czasu, a także umożliwić analizę ilościowych i jakościowych zależności pomiędzy wynikami eksperymentów z różnych obszarów badawczych.

Podziękowanie

Praca została zrealizowana w ramach projektu badawczego nr N N519 441939.

Konflikt interesów / Conflict of interest

Brak/None

Adres do korespondencji:

✉ Maciej Komosiński

Instytut Informatyki, Politechnika Poznańska

ul. Piotrowo 2; 60-965 Poznań

☎ (+48) 61 665 2931

✉ maciej.komosinski@cs.put.poznan.pl

Piśmiennictwo

1. Buhusi CV, Meck VH. What makes us tick? Functional and neural mechanisms of interval timing. *Nat Rev Neurosci* 2005;6:755-65.
2. Grondin S. From physical time to the first and second moments of psychological time. *Psychol Bull* 2001;127:22-44.
3. Friedman W. *The Mind Timekeepers*. MIT Press; 1990.
4. Gerstner W. Spiking neurons. In: Maass W, Bishop ChM (editors). *Pulsed Neural Networks*. MIT Press; 1999. pp. 1-54.
5. Grondin S. Timing and time perception: A review of recent behavioral and neuroscience findings and theoretical directions. *Atten Percept Psychophys* 2010;72:561-82.
6. Zakay D, Block RA, Tsal Y. Prospective duration estimation and performance. In: Gopher D, Koriat A (eds). *Attention and Performance* 1999;XVII:557-80. MIT Press, 1999.
7. Gibbon J, Church RM, Meck WH. Scalar Timing in Memory. *Ann N Y Acad Sci* 1984;423:52-77.
8. Gibbon J. Ubiquity of scalar timing with Poisson clock. *J Math Psychol* 1992;35:283-93.
9. Rammsayer T, Ulrich R. Counting models of temporal discrimination. *Psychon Bull Rev* 2001;8:270-7.
10. Eisler H. Applicability of the parallel-clock model to duration discrimination. *Atten Percept Psychophys* 1981;29:225-33.
11. Karmarkar UR, Buonomano DV. Telling time in the absence of clocks. *Neuron* 2007;53:427.
12. Buonomano DV, Bramen J, Khodadadifar M. Influence of the interstimulus interval on temporal processing and learning: testing the state- dependent network model. *Philos Trans R Soc* 2009;B, 364:1865-73.
13. Ivry RB, Schlerf JE. Dedicated and intrinsic models of time perception. *Trends Cogn Sci* 2008;12:273-80.
14. Lewis PA, Miall RC. The precision of temporal judgement: milliseconds, many minutes and beyond. *Philos Trans R Soc Lond B Biol Sci* 2009;364:1897-905.
15. Rammsayer TH, Lima SD. Duration discrimination of filled and empty auditory intervals: Cognitive and perceptual factors. *Atten Percept Psychophys* 1991;50:565-74.
16. Wearden JH, Denoyan L, Fakhri M, Haworth R. Scalar timing in temporal generalization in humans with longer stimulus durations. *J Exp Psychol Anim Behav Process* 1997;23:502-11.
17. Matell MS, Meck WH. Cortico-striatal circuits and interval timing: coincidence detection of oscillatory processes. *Cognit Brain Res* 2004;21:139-70.
18. Rammsayer TH, Grondin S. Psychophysics of human timing. In: Robert Miller (editor). *Time and the brain*. Harwood Academic Publishers, 2000. Pp. 157-168.
19. Komosinski M. Sztuczne życie. Algorytmy inspirowane biologicznie. *Nauka* 2008;4:7-21.
20. Komosinski M. Życie w komputerze: symulacja czy rzeczywistość? *Nauka* 2011;2:83-93.
21. Komosinski M, Adamatzky A (editors). *Artificial Life Models and Software*. 2nd (revised and expanded) Ed. London: Springer; 2009.
22. Adamatzky A, Komosinski M (editors). *Artificial Life Models in Hardware*. London: Springer; 2009.
23. Tadeusiewicz R. *Sieci Neuronowe*. Warszawa: Akademicka Oficyna Wydawnicza RM; 1993.
24. Wearden JH. Applying the scalar timing model to human time psychology: Progress and challenges. In: Helfrich H (editor). *Time and mind II: Information processing perspectives*. Hogrefe & Huber Publishers; 2003. p. 21-39.
25. Komosinski M, Kups A. Models and implementations of timing processes using Artificial Life techniques. Technical Report RA-05/09, Poznan University of Technology, Institute of Computing Science, 2009.
26. Komosinski M, Kups A. Implementation and simulation of the Scalar Timing Model. *Bio-Algorithm Med-Syst* 2011;7:41-52.
27. Komosinski M, Ulatowski Sz. Framsticks: Creating and understanding complexity of life. In: Komosinski M, Adamatzky A (editors). *Artificial Life Models in Software*. 2nd Ed. Chapter 5. London: Springer; 2009. pp. 107-148.
28. Wearden JH. "Beyond the fields we know...": exploring and developing scalar timing theory. *Behav Process* 1999;45:3-21.
29. Hellström Å. The time-order error and its relatives: Mirrors of cognitive processes in comparing. *Psychol Bull* 1985;97:35-61.
30. Allan LG. The time-order error in judgments of duration. *Can J Psychol* 1977;31:24-31.
31. Schab FR, Crowder RG. The role of succession in temporal cognition: Is the time-order error a recency effect of memory? *Percept Psychophys* 1988;44:233-42.
32. Needham JG. The effect of the time interval upon the time-error at different intensive levels. *J Exp Psychol* 1935;18:530-43.
33. Jamieson DG, Petrusic WM. Presentation order effects in duration discrimination. *Percept Psychophys* 1975;17:197-202.
34. Jamieson DG, Petrusic WM. Pairing effects and time-order errors in duration discrimination. *Percept Psychophys* 1975;18:107-13.
35. Hairston IS, Nagarajan SS. Neural mechanisms of the time-order error: An MEG study. *J Cogn Neurosci* 2007;19:1163-74.
36. Jamieson DG, Petrusic WM. The dependence of time-order error direction on stimulus range. *Can J Psychol* 1975;29:175-82.
37. Stott LH. Time-order errors in the discrimination of short tonal durations. *J Exp Psychol* 1935;18:741-66.
38. Woodrow H. The effect of practice upon time-order errors in the comparison of temporal intervals. *Psychol Rev* 1935;42:127-52.
39. Hellström Å, Rammsayer TH. Effects of time-order, interstimulus interval, and feedback in duration discrimination of noise bursts in the 50- and 1000-ms ranges. *Acta Psychol* 2004;116:1-20.

40. Hellström Å, Eisler H, Eisler AD. Psychophysical issues in the study of time perception. In: Grondin S (editor). *Psychology of Time*. Emerald Group Publishing Ltd; 2008. pp.75-110.
41. Wiener M, Hamilton R, Turkeltaub P, Matell MS, Coslett HB. Fast forward: supramarginal gyrus stimulation alters time measurement. *J Cogn Neurosci* 2010;22:23-31.
42. Sévigny MC, Everett J, Grondin S. Depression, attention, and time estimation. *Brain Cogn* 2003;52:351-3.
43. Jared G Smith, David N Harper, David Gittings, and David Abernethy. The effect of Parkinson's disease on time estimation as a function of stimulus duration range and modality. *Brain Cogn* 2007;64:130-43.
44. Perbal S, Deweer B, Pillon B, Vidailhet M, Dubois B, Pouthas V. Effects of internal clock and memory disorders on duration reproductions and duration productions in patients with Parkinson's disease. *Brain Cogn* 2005; 58:35-48.
45. Riesen JM, Schnider A. Time estimation in Parkinson's disease: normal long duration estimation despite impaired short duration discrimination. *J Neurol* 2001;248:27-35.
46. Malapani C, Rakitin B, Levy R, Meck WH, Deweer B, Dubois B, et al. Coupled temporal memories in Parkinson's disease: a dopamine-related dysfunction. *J Cogn Neurosci* 1998;10:316-31.
47. Hellström Å, Lang H, Portin R, Rinne J. Tone duration discrimination in Parkinson's disease. *Neuropsychologia* 1997;35:737-40.
48. Rammesayer T, Classen W. Impaired temporal discrimination in Parkinson's disease: temporal processing of brief durations as an indicator of degeneration of dopaminergic neurons in the basal ganglia. *Int J Neurosci* 1997;91:45-55.