

Krzysztof T. Piotrowski Michał Wierchoń Zbigniew Stettner

Uniwersytet Jagielloński,
Instytut Psychologii
Studium PedagogiczneUniwersytet Jagielloński,
Instytut PsychologiiUniwersytet Jagielloński,
Instytut Psychologii

OCENA SEKWENCYJNOŚCI SZTUCZNYCH GRAMATYK¹

Autorzy badań nad uczeniem mimowolnym prowadzonych w paradygmacie uczenia się sztucznych gramatyk często tworzą i wykorzystują nowe gramatyki, nie zwracając uwagi na możliwe zależności między specyfiką wykorzystywanych reguł i efektywnością procesu uczenia. W niniejszym artykule dyskusji poddane zostaną teoretyczne i metodologiczne konsekwencje uwzględnienie tych zależności. Zaproponowano i zaprezentowano wyniki analizy porównania sekwencyjności sześciu zbiorów reguł, wykorzystywanych w zadaniach uczenia się sztucznych gramatyk. Do oszacowania sekwencyjności gramatyk zastosowano metody analizy losowości używane w badaniach generowania liczb losowych. Zobserwowano różnice między wybranymi zestawami reguł, co wskazuje na konieczność uwzględniania parametru sekwencyjności reguł w planowaniu eksperymentów z wykorzystaniem zadania uczenia się sztucznych gramatyk.

Słowa kluczowe: Uczenie mimowolne, sztuczne gramatyki, sekwencyjność, ocena losowości

WPROWADZENIE

Niniejszy artykuł poświęcony jest ograniczeniom procedury uczenia się sztucznych gramatyk (*artificial grammar learning*, AGL), jednej z najbardziej popularnych metod badania procesu uczenia mimowolnego. W badaniach z wykorzystaniem tego zadania zakłada się, że ludzie potrafią nabywać informacje dotyczące złożonych reguł, nie zdając sobie z tego sprawy. Typowy eksperyment prowadzony w omawianym paradygmacie składa się z dwóch faz. W pierwszej, badani proszeni są o zapamiętanie ciągów liter (najczęściej spółgłosek, które nie tworzą jednak całości posiadających jakieś znaczenie w języku naturalnym). Następnie, po prezentacji kilku do

kilkunastu ciągów, badani informowani są, że zaprezentowany wcześniej materiał stworzony został według określonego zbioru reguł (to znaczy, że kolejność liter w analizowanych ciągach nie była przypadkowa). W kolejnej fazie badania, zadaniem uczestników jest zazwyczaj określenie, czy nowe, nie prezentowane dotychczas ciągi spełniają te reguły, czy nie (por. np. Dienes i Scott 2005). Badani zazwyczaj deklarują, że nie zdają sobie sprawy z istnienia żadnych reguł, jednak potrafią klasyfikować ciągi lepiej, niż wynikałoby to z oszacowania poziomu losowego.

Co ciekawe, w badaniach z wykorzystaniem paradygmatu AGL praktycznie pomija się związek uzyskiwanych wyników z charakterem zbioru reguł wykorzystywanych w eksperymencie.

¹ Projekt finansowany z grantu badawczego NCN nr N N106 052636, Transfer uprzedniej wiedzy w uczeniu mimowolnym.

Badacze stosują różne gramatyki zakładając, że niezależnie od ich rodzaju nabywanie wiedzy przebiega w taki sam sposób. Niniejszy artykuł poświęcony będzie analizie tych podstawowych założeń, które związane wydają się z problemem formy reprezentacji wiedzy nabywanej w toku procesu uczenia mimowolnego. Założenia te będą dyskutowane z punktu widzenia różnic reguł stosowanych w badaniach. Zgodnie z naszymi przewidywaniami, mogą one wpływać na formę reprezentacji wiedzy, a przez to na poprawność wykonywania zadania uczenia się sztucznych gramatyk.

Badacze spierają się, czy wiedza nabywana w trakcie omawianego procesu jest rzeczywiście nieświadoma, i w jaki sposób jest ona reprezentowana. Pierwotnie Reber (1969) proponował, że osoby badane, poprzez obserwację egzemplarzy ciągów gramatycznych, uczą się abstrakcyjnych reguł. Brooks (1978) założył, że badani uczą się egzemplarzy całych ciągów, zaś Perruchet i Pacteau (1990) zaproponowali, że badani uczą się tylko ich fragmentów. Inni autorzy (Pothos i Bailey 2000) wskazywali, że poprzez wielokrotne prezentowanie ciągów regularnych, badani mogą uczyć się prawdopodobieństwa pojawienia się kolejnego stanu. Analizując różne teorie reprezentacji wiedzy nabywanej w zadaniu uczenia się sztucznych gramatyk, najbardziej interesującym kierunkiem wyjaśnienia zjawiska uczenia mimowolnego wydaje się uczenie skojarzeniowe (Pothos 2007). W ujęciu tym proponuje się, że statystyczną poprawność klasyfikacji w zadaniu AGL można tłumaczyć poprzez asocjacyjne uczenie się elementów współwystępujących w ciągu. Szczególną uwagę poświęcono uczeniu się zlepków elementów występujących bezpośrednio po sobie (*chunks*), zakładając, że forma reprezentacji wiedzy opiera się na pamiętaniu krótkich fragmentów prezentowanych ciągów (Servan-Scriber i Anderson, 1990).

Opierając się na powyższej koncepcji Pothos (2010) zaproponował model entropii, który zakłada, że ludzie uczą się rozpoznawać własności

statystyczne ciągów w oparciu o zlepki elementów. To podejście różni się od koncepcji uczenia prawdopodobieństwa elementów w całym ciągu (por. np. Perruchet 2008), gdyż ogranicza szacowanie prawdopodobieństwa do krótkich, dwu i trzelementowych łańcuchów. W opisywanym modelu zaproponowano więc ocenę charakteru reprezentacji, poprzez szacowanie prawdopodobieństwa wystąpienia bigramów i trigramów określonego typu w ciągach prezentowanych badanym. Pothos (2010) wykorzystywał w tym celu miarę entropii.

Wydaje się, że niezależnie od przyjmowanej teorii reprezentacji wiedzy nabywanej w trakcie zadania AGL, wykorzystanie reguł opartych na łańcuchach Markowa sprawia, że podstawową cechą sztucznych gramatyk jest sekwencyjność reguł. Zarówno koncepcje oparte na ocenie przewidywalności pojawiania się liter w całym ciągu, jak i uczenia skojarzeniowego zlepków literowych zakładają, że osoby badane wykorzystują w uczeniu mimowolnym informację o kolejności elementów. Przy dużej różnorodności sztucznych gramatyk proponowanych w literaturze, można zadać pytanie, czy nie różnią się one stopniem sekwencyjności reguł, a jeżeli tak, to również o wpływ różnic w sekwencyjności materiału na proces uczenia mimowolnego. Drugie pytanie, jakie rodzi się w tym miejscu, to czy osoby badane będą uczyły się gramatyk opartych na innych, niesekwencyjnych regułach.

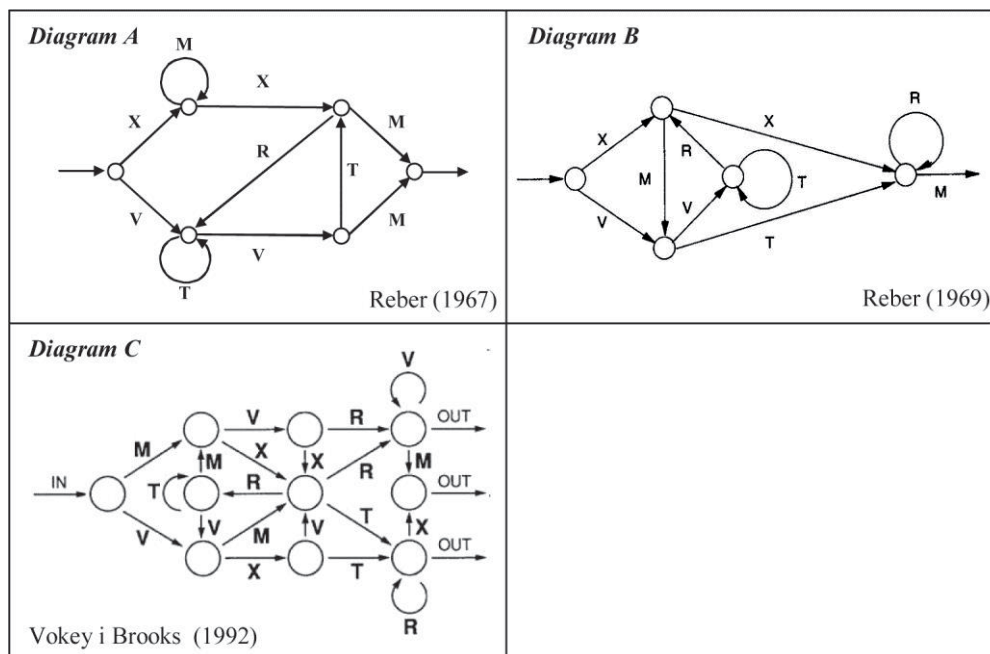
Sekwencyjność w gramatykach

Badacze zajmujący się problematyką uczenia mimowolnego, tworzą zestawy reguł o różnym stopniu skomplikowania. Najczęściej, do tworzenia reguł sztucznych gramatyk wykorzystywany jest aparat Markowa ze skończoną liczbą stanów (Reber 1967, 1969, Reber i Allen 1978, Vokey i Brooks 1992, Knowlton i Squire 1996, Altmann, Dienes i Goode 1995). Tak utworzony zestaw reguł pozwala na generowanie ciągów poprzez dyskretne przechodzenie z jednego sta-

nu łańcucha Markowa do następnego. Kolejne możliwe stany w łańcuchu, zależą jedynie od stanu poprzedniego. Przykładowo, po literze M możliwe są jedynie stany V albo X, po V - tylko R albo X, i tak dalej.

Reber (1967, 1969), tworząc swoje gramatyki (por. ryc. 1. Diagramy A i B), zaprojektował je tak, aby prawdopodobieństwa osiągnięcia kolejnych stanów w każdym miejscu łańcucha były identyczne. Każdy kolejny stan w gramatykach jego autorstwa, jest osiągalny z prawdopodobieństwem równym 0,5. Gramatyki stworzone przez innych autorów często jednak wprowadzają stany osiągalne z mieszaną wartością prawdopodobieństwa kolejnych stanów, np. 0,5 i 0,33 (Knowlton i Squire 1996, Tunney i Altman 2001 oraz Vokey i Brooks 1992 – por. ryc. 1 Diagram C). Wydaje się, że prawdopodobieństwo kolejnych stanów gramatyki może moderować efektywność analizowanego procesu, wpływając na przewidywalność sekwencji elementów w ciągach.

W zadaniu uczenia się sztucznych gramatyk poprawność w fazie klasyfikacji (testowej) zależy zarówno od trafnego rozpoznania częstości pojawiania się elementów, jak i ich wzajemnego położenia w sekwencji ciągu. Analizy efektu transferu obserwowanego w tym zadaniu (Tunney i Altman 2001, Vokey i Brooks 1992) wskazują, że badani potrafili kierować się regułami sekwencyjnymi, niezależnie od formy samych elementów: np. wzorec XYYYYX, może być rozpoznawany w układzie ABBBA. Na tej zasadzie możliwy jest transfer również na inny rodzaj materiału, np.: •■ ■ ■ •. Badani mogą jednak kierować się także częstością pojawiania się danego elementu w fazie uczenia, klasyfikując jako gramatyczne ciągi, w których litera X pojawiła się odpowiednią ilość razy (przykładowo, jeśli w ciągu nie występuje litera X, to ciąg taki może być uznany za niegramatyczny). Przykład gramatyki dwuwarunkowej (ryc. 2. Diagram A), wskazuje na to, że zasadę występowania lub nie



Ryc. 1. Schematy sekwencyjnych sztucznych gramatyk: Diagram A - gramatyka Rebera (1967); Diagram B - gramatyka Rebera (1969); Diagram C - gramatyka Vokeya i Brooksa (1992);

danego elementu można wykorzystać, jako istotny warunek gramatyczności.

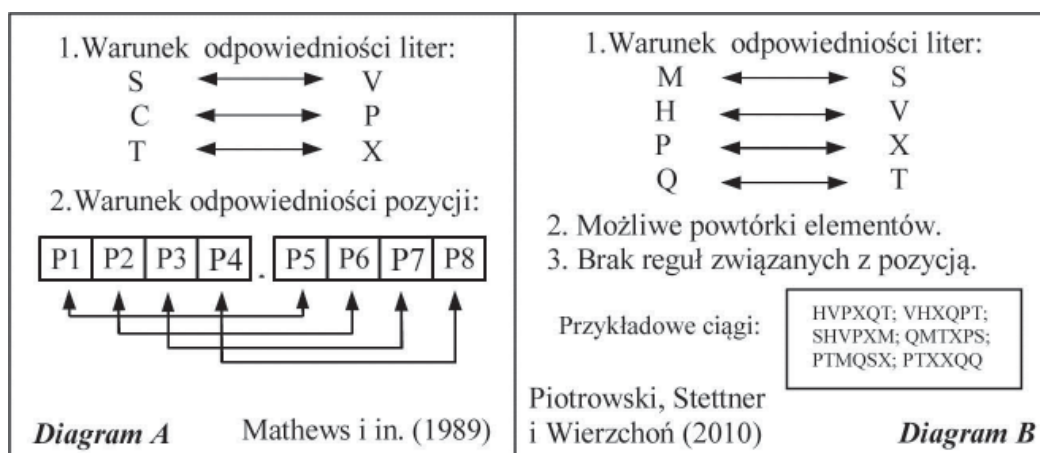
Postawione wcześniej pytanie o to czy gramatyki różnią się poziomem sekwencyjności, związane jest przede wszystkim z rolą, jaką w danej gramatyce pełni pozycja poszczególnych elementów w ciągu. Pothos (2007, 2010) twierdzi, że uczenie związane jest ze wzrostem prawdopodobieństwa pojawienia się danej zbitki elementów, co sprowadza się, w gruncie rzeczy, do oszacowania prawdopodobieństwa następstwa jednego elementu po innym. W tym ujęciu, prawdopodobnie nie wszystkie gramatyki będą charakteryzowały się takim samym stopniem entropii. Innymi słowy, sekwencje zbudowane na podstawie założonej w gramatyce reguły będą mniej lub bardziej regularne. Gramatyka określana przez nas jako bardziej sekwencyjna, byłaby zatem zbiorem reguł związanych z większą przewidywalnością kolejności elementów. Gramatyka mniej sekwencyjna – zbiorem reguł związanych z większą entropią, gdzie układ kolejności elementów w ciągach możnaby określić jako bardziej losowy. Gramatyki niesekwencyjne byłyby zatem zestawem reguł, gdzie sekwencja poszczególnych stanów jest znacznie bardziej nieprzewidywalna. Wprowadzenie analizy sekwencyjności materiału do badań procesu uczenia mimowolnego prowokuje również do postawienia pytania o to, czy możliwe jest stworzenie sztucznej gramatyki, która nie opierałaby się na sekwencyjnej regule organizacji materiału. Reguły w materiale zbudowanym na podstawie takiej gramatyki nie mogłyby zostać wykryte w oparciu o szacowanie prawdopodobieństwa następstwa pojedynczych elementów, bigramów lub trigramów. Nieefektywne byłoby też zapamiętywanie innych wzorców sekwencyjności wskazujących na gramatyczność materiału (np. typowych początków lub zakończeń ciągów czy charakterystycznych powtórek liter).

Mathews i współpracownicy (1989) skonstruowali sztuczną gramatykę, w której o regularności ciągów decydują dwa warunki gramatyczno-

ści (ta gramatyka nazywana jest dwuwarunkową). Pierwszym z nich jest współwystępowanie par liter w lewej i prawej części ciągu (a więc nie chodzi tu o zbitki literowe – por. ryc. 2. Diagram A), drugim – możliwa pozycja tych liter w ciągu. Analizowana gramatyka jest więc zbiorem reguł stworzonych w taki sposób, że pierwsze cztery stany ciągu (lewa część) nie zależą sekwencyjnie od poprzednich. Natomiast ostatnie cztery, zależą od poszczególnych stanów pierwszej połowy ciągu. Analizując rozkład entropii w takiej gramatyce, w pierwszej połowie byłaby ona równa 1, a w drugiej 0. Podobne założenia przyświecały autorom tego tekstu, którzy zaproponowali nową gramatykę niesekwencyjną (Piotrowski, Stettner i Wierzchoń 2010, 2011, por. ryc. 2. Diagram B) opierającą się na ustanowieniu reguł opartych jedynie na warunku współwystępowania przy pominięciu roli pozycji elementu w ciągu.

W literaturze wciąż brakuje wyczerpującego przeglądu porównawczego stosowanych gramatyk. Badacze, skupiają się zazwyczaj na tym, czy osoby badane uczą się mimowolnie, wprowadzając nowe zestawy reguł, albo porównując uczenie się tych samych gramatyk z wykorzystaniem różnych zestawów elementów (np. efekt transferu, por. Pothos 2010). Co ciekawe, nie analizowano dotąd, jak różnorodność reguł wykorzystywanych w gramatykach wpływa na proces uczenia. Sam fakt istnienia różnic w prawdopodobieństwach kolejnych stanów w różnych regułach stworzonych na podstawie łańcucha Markowa, pozwala przypuszczać, że rodzaj gramatyki może wpływać na wyniki badań.

Zgodnie z koncepcją wyjaśniającą fenomen uczenia mimowolnego sztucznych gramatyk przez odwołanie do tworzenia reprezentacji prawdopodobieństwa pojawienia się danego elementu w ciągu (Pothos 2010), można założyć, że im większe prawdopodobieństwo pojawienia się kolejnego stanu tym łatwiejsza klasyfikacja ciągów zbudowanych na tej gramatyce. Jeśli gramatyka zakłada możliwość pojawienia się, po jednym stanie łańcucha, któregoś z trzech równie



Ryc. 2. Schematy tworzenia ciągów w oparciu o gramatykę: dwuwarunkową (Mathews i in 1989) - Diagram A i gramatykę niesekwencyjną (Piotrowski, Stettner i Wierchoń 2010) – Diagram B.

prawdopodobnych stanów (tak jest np. w gramatyce Vokeya i Brooksa), to taka gramatyka będzie trudniejsza do nauczenia niż ta, w której możliwe są tylko dwa prawdopodobne stany (obie gramatyki Rebera). Gramatyki zbudowane w oparciu o inne zasady niż aparat Markowa, gdzie możliwości pojawienia się konkretnego kolejnego elementu ciągu jest mniejsze niż 0,5 czy 0,33, będą prawdopodobnie jeszcze trudniejsze do uczenia.

Powyższe przewidywania, oparte na koncepcji Pothosa są zasadniczo zgodne z wynikami eksperymentów opisywanymi w literaturze. W badaniach nad uczeniem się mimowolnym z wykorzystaniem procedury AGL osoby badane uzyskują różne poziomy poprawnego klasyfikowania. Przykładowo, w badaniach z wykorzystaniem gramatyki Rebera (1967) prowadzonych przez Rebera, Walkenfeld i Hernstadt (1991) poprawność klasyfikowania wyniosła 0,61. Dienes i Scott (2005) uzyskali w obu gramatykach Rebera użytych łącznie poziom poprawności równy 0,64. Badania z wykorzystaniem gramatyki Vokeya i Brooksa, choć w nieco innej procedurze badawczej (Vokey i Brooks 1992), dały wyniki poprawnej klasyfikacji ciągów na poziomie 0,53. Zadania oparte na gramatyce Mathewsa i in. dały wyniki poprawności klasyfikowania na po-

ziomie 0,52 - jedynie nieco wyższym niż losowy (Cock 2005, eksperyment 1) lub nie różniły się od losowego (Cock 2005, eksperyment 2).

Metoda porównania sekwencyjności reguł sztucznych gramatyk

By zweryfikować wyżej postawione przypuszczenia, poszukiwaliśmy wskaźników, za pomocą których można porównać poziom prawdopodobieństwa pojawiania się kolejnych elementów w ciągach opartych na różnych typach sztucznych gramatyk. Przypisanie poszczególnym gramatykom stopnia przewidywalnej sekwencji (co w tym tekście określamy jako poziom sekwencyjności gramatyki) pozwoli odnieść ten parametr do wyników uczenia mimowolnego tych gramatyk w zadaniach behawioralnych.

By oszacować poziom sekwencyjności analizowanego materiału wykorzystana została przez nas analiza wskaźników losowości. Proponowana metoda opiera się na założeniach podobnych do tych, które wykorzystano w opisywanych wyżej badaniach Pothosa (2010). W tamtych badaniach nie analizowano jednak różnic pomiędzy gramatykami, a jedynie wykorzystywano pomiar entropii

pii bigramów i trigramów dla uzasadnienia tezy o statystycznej naturze uczenia mimowolnego.

W badaniach psychologicznych, w których zachodzi potrzeba oszacowania losowości albo stopnia uporządkowania jakiegoś zestawu danych (np. losowości reakcji badanych albo losowości danych prezentowanych badanym) wykorzystuje się wiele różnych wskaźników. Każdy z nich kładzie nacisk na inny aspekt losowości, na przykład: rozkład poszczególnych elementów w sekwencji, zależności między kolejnymi elementami ciągu czy inny sposób uporządkowania materiału (np. w ciągach liczb podawanych przez ludzi w zadaniu generowania liczb losowych można zaobserwować tendencję do odliczania, czyli podawania kolejnych elementów rosnącego bądź malejącego ciągu). Wszystkie wymieniane w literaturze metody analizy losowości materiału można jednak zaliczyć do jednej z kilku grup (Miyake, Witzki i Emerson 2001, Friedman i Miyake 2004, Towse i Neil 1998). Pierwsza grupa wskaźników dotyczy równości rozkładu poszczególnych opcji w analizowanych ciągach. Druga grupa zawiera wskaźniki dotyczące związków między kolejnymi elementami ciągu (np. wskaźniki określające, czy ciąg zawiera elementy odliczania). Trzecia grupa to wskaźniki dotyczące powtarzalności tej samej opcji w różnych odstępach.

Wydaje się, że do analizy sekwencyjności materiału prezentowanego badanym w zadaniu uczenia się sztucznych gramatyk zastosowanie znajdują przede wszystkim wskaźniki z pierwszej grupy. Druga grupa nie mogła zostać użyta, ze względu na stosowany w większości badań nad sztucznymi gramatykami materiał (w analizowanych gramatykach wykorzystuje się kilka spółgłosek, które trudno w prosty sposób ułożyć według jakiegoś porządku, tak aby zaobserwować np. ciągi są rosnące bądź malejące). Ze względu na charakterystykę analizowanego materiału nie da się również oszacować wskaźników z trzeciej grupy. Ciągi wykorzystywane w zadaniu uczenia się sztucznych gramatyk są zazwyczaj dosyć

krótkie, a analiza powtarzalności opcji lub ich zestawów w różnych odstępach wymaga długich, najlepiej kilkudziesięcioelementowych ciągów.

Ze względu na wspomniane ograniczenia, sekwencyjność analizowanych w ramach niniejszego tekstu gramatyk zostanie oszacowana z wykorzystaniem wskaźników rozkładu poszczególnych opcji w ciągach, a więc redundancji (R) i dwóch wskaźników rozkładu par elementów (RNG i RNG2).

Wskaźnik redundancji (R) opisuje rozkład poszczególnych opcji możliwych do wykorzystania w danym ciągu (w przypadku gramatyk – rozkład częstotliwości wykorzystania poszczególnych elementów, np. liter). Jeśli rozkład nie jest równy obserwujemy redundancję materiału, a więc sytuację, w której prawdopodobieństwo pojawienia się jakiejś opcji (w naszym przypadku np. litery) jest większe niż innych. Wskaźnik R obliczany jest na podstawie wzoru:

$$R = \frac{H_s}{n} - \sum_{i=1}^n \frac{p_i^2}{n} \quad (1)$$

gdzie n oznacza liczbę elementów ciągu oraz i oznacza liczbę wystąpień elementu i .

Inne wskaźniki pozwalające na oszacowanie rozkładu poszczególnych opcji w analizowanych ciągach to wskaźnik rozkładu par elementów (RNG, por. Evans 1978), opisujący rozkład występowania możliwych par elementów w analizowanym ciągu, a także podobny do niego wskaźnik RNG2, za pomocą którego szacowany jest rozkład par elementów rozdzielonych innym elementem.

Szczegółowe omówienie wszystkich wskaźników odnaleźć można w innych pracach (por. Towse 1998, Barbasz, Stettner, Wierchoń, Piotrowski i Barbasz 2008). W przypadku wszystkich trzech wskaźników, wyższy wynik oznacza, większe odchylenie od losowości, co wskazuje na większą przewidywalność ciągów w sekwencji, a także (szczególnie w przypadku wskaźników RNG i RNG2) ich sekwencyjność.

Analiza porównawcza wybranych reguł sztucznych gramatyk

Do porównania wybrano cztery gramatyki opisywane często w badaniach nad uczeniem mimowolnym, publikowanych wcześniej w literaturze - dwie gramatyki zaproponowane przez Rebera (1967, 1969), gramatykę Vokeya i Brooksa (1992) oraz gramatykę Mathewsa i współpracowników (1989). W porównaniu uwzględniono również nową, niesekwencyjną gramatykę autorstwa Piotrowskiego i Stettnera (Piotrowski, Stettner i Wierchoń 2010, 2011). Porównanie tych gramatyk pozwoli na oszacowanie wpływu zróżnicowania ciągów, na podstawie których ocenia się uczenie mimowolne. Będzie także podstawą analizy różnic między zestawami reguł, która uwzględniać będzie stopień sekwencyjności prezentowanych badanych elementów.

a. Gramatyka Rebera *A* (1967)

Gramatyka zaproponowana przez Rebera (1967) zawiera zestaw reguł zorganizowanych zgodnie z automatem Markowa, który pozwala na uporządkowanie liter w sekwencji (por. ryc. 1. Diagram A). Tworzenie ciągów dokonuje się poprzez przechodzenie od jednego stanu gramatyki do następnego według arbitralnie zdefiniowanych możliwych wyborów między stanami. Reguły gramatyki dają możliwość wyboru jednego z dwóch stanów następujących po stanie aktualnym. W przedstawionym na Rycinie 1 (Diagram A) schemacie gramatyki, strzałkami oznaczone zostały wszystkie możliwe połączenia między stanami, budujące sekwencyjne połączenia elementów. Wykorzystując ten zestaw reguł można tworzyć ciągi liter o różnej długości. Kryterium gramatyczności ciągu opiera się na tym, czy kolejność wszystkich liter w ciągu jest zgodna z regułami zawartymi w gramatyce. Regułę komplikuje dodatkowo fakt powtarzania się tych samych liter pomiędzy różnymi stanami gramatyki. W efekcie każdy z ciągów gramatycznych zawiera przynajmniej jedno powtórzenie litery. Przykładem ciągów regularnych,

zbudowanych na podstawie reguły, są na przykład ciągi XMXM, XXRVTM czy VTTTVTM. Zmiana pozycji liter w tych ciągach może spowodować, że przestaną być one gramatyczne (np. MXXM, XRXVTM czy VTTVTM). Ponieważ jednak litery powtarzają się w ramach różnych połączeń stanów opisywanych przez gramatykę, zmiana kolejności elementów może, w niektórych przypadkach, nie wpływać na gramatyczność ciągu (np. VTTTTVM). Należy pamiętać, że w badaniach nie wykorzystuje się wszystkich możliwych do utworzenia ciągów, ale dobiera się materiał tak, aby w fazie uczenia i klasyfikacji pojawiły się egzemplarze wykorzystujące wszystkie przejścia między stanami zakładane przez gramatykę.

b. Gramatyka Rebera *B* (1969)

Zaproponowana gramatyka (Reber, 1969) jest bardzo podobna do gramatyki Rebera z 1967r. (por. ryc. 1. Diagram B). Zmiany wprowadzone przez autora dotyczyły zestawu liter. Podobnie jak w przypadku poprzedniego zbioru reguł, połączenia między stanami pozwalają wybrać jeden z dwóch możliwych stanów następujących po stanie aktualnym. Przykładem ciągów gramatycznych, zbudowanych na podstawie tej gramatyki, są ciągi TLTRJ, XTPRJ czy XTPPRLV. Bardziej restrykcyjnie, niż w poprzedniej gramatyce, zmiana kolejności elementów w ciągu będzie powodować, że stanie się on niegramatyczny (np. ciąg niegramatyczny TLPRTJ).

c. Gramatyka Vokeya i Brooksa (1992)

Gramatyka zaproponowana przez Vokeya i Brooksa (1992) zbudowana została na podobnych zasadach jak reguły opisane powyżej, jest jednak zdecydowanie bardziej złożona (por. ryc. 1. Diagram C). Umożliwia tworzenie większej liczby ciągów niż zaprezentowane dotąd gramatyki. Pozwala również znacznie zróżnicować ostatnie elementy ciągów. Podobnie jak wszystkie inne gramatyki oparte na automacie Markowa, analizowana gramatyka opiera się na sekwencyjnej organizacji materiału. Przykładem poprawnych ciągów skonstruowanych na

podstawie tej gramatyki są MXRVV, VMRVXT czy MXTRRX. Podobnie jak w poprzednich gramatykach, zmiana kolejności elementów w ciągu może, ale nie musi powodować, że stanie się on niegramatyczny (np. ciąg niegramatyczny MRXVV, ciąg gramatyczny VXVRM).

d. Dwuwarunkowa gramatyka Mathewsa i współpracowników (1989).

Gramatyka Mathewsa i współpracowników (1989) jest przykładem gramatyki, w części opartej na regułach niesekwencyjnych. Wykorzystuje się w niej koniunkcję dwóch reguł (warunków koniecznych). Pierwsza, opiera się na powiązaniu liter prezentowanych w prawej i lewej części ciągu, druga na powiązaniu pozycji w ciągu. Powiązanie liter polega na przyporządkowaniu liter parami (por. ryc. 2. Diagram A) - w każdym ciągu gramatycznym muszą występować kompletne pary liter. Powiązanie pozycyjne zakłada wpływ pozycji litery prezentowanej w lewej połowie ciągu, na pozycję powiązanej z nią w parze litery, w części prawej. Przykładowo, w ośmioelementowym ciągu stworzonym na podstawie gramatyki dwuwarunkowej, literze S na miejscu pierwszym, (oznaczonym na ryc. 2. Diagram A, jako P1) odpowiadać powinna litera C na miejscu piątym (P5). Innymi przykładami ciągów gramatycznych są więc ciągi SCXT.VPTX, lub PVCC.CSPP. Zmiany w kolejności elementów łamią jednak warunek odpowiedniości powodując, że ciągi stają się niegramatyczne (np. SXCT.PVTX; CVPC.CSPP).

e. Niesekwencyjna gramatyka Piotrowskiego i Stettnera (Piotrowski, Stettner i Wierchoń 2010, 2011).

Przy konstrukcji gramatyki niesekwencyjnej Piotrowskiego i Stettnera (Piotrowski, Stettner i Wierchoń 2010, 2011) wykorzystano, opisaną w kontekście gramatyki dwuwarunkowej, regułę powiązania liter. Zrezygnowano natomiast z prowadzącego do bardziej sekwencyjnego układu elementów, warunku odpowiedniości pozycji. Współwystępowanie liter z ustalonych par (M-S, H-V, P-X i Q-T) jest tu jedyną regu-

łą istotną dla gramatyczności ciągu (por. ryc. 2. Diagram B). Założono, że powtarzalność danej litery w ciągu nie będzie mieć znaczenia dla gramatyczności ciągu, pod warunkiem, że każda z określonych w regule par elementów pojawi się przynajmniej raz. Przykładowo, gramatyczny będzie ciąg MMMSM, bo obie litery z pary M-S pojawiły się co najmniej raz. Na gramatyczność ciągu nie ma także wpływu kolejność występowania liter w ciągu. W przeciwieństwie zatem do wszystkich opisanych wcześniej gramatyk, zmiana pozycji liter w ciągu nie powoduje, że staje się on niegramatyczny. Przykładem ciągów gramatycznych, utworzonych w ramach analizowanego zbioru reguł są ciągi MHSSV i SHSMVH. Przykładem ciągu niegramatycznego jest PQXMTT, bo nie została w nim uwzględniona litera S, będąca konieczną parą do obecnej w ciągu litery M.

Porównanie wybranych reguł sztucznych gramatyk z wykorzystaniem wskaźników losowości

Opisane gramatyki zostały dobrane w taki sposób, by poddać analizie różne możliwe przyczyny regularności utworzonych w oparciu o nieciągów, możliwe do zaobserwowania z wykorzystaniem wskaźników losowości.

Pierwsza z możliwych przyczyn regularności to zastosowanie gramatyki opartej na automacie Markowa. W analizowanym zbiorze gramatyk na tej podstawie utworzone zostały obydwie gramatyki Rebera (1967, 1969), Rebera (1969) oraz gramatyka Vokeya i Brooksa (1992). Gramatyki, dwuwarunkowa Mathewsa i współpracowników (1989) oraz niesekwencyjna Piotrowskiego i Stettnera (Piotrowski, Stettner i Wierchoń 2010, 2011), nie wykorzystują zasad opartych na automacie Markowa. Założono, że w przypadku ciągów utworzonych z wykorzystaniem gramatyk opartych o automat Markowa, wskaźniki R, RNG i RNG2 będą mniej losowe, odzwierciedlając wyższą sekwencyjność materiału.

Druga z możliwych przyczyn obserwowanej regularności jest związana z prawdopodobieństwem następstwa stanów w łańcuchu Markowa. Założone w określonej gramatyce przejścia między stanami dają możliwość wyboru jednego z dwóch lub trzech możliwych stanów następnym, a więc gramatyka określa prawdopodobieństwo wystąpienia kolejnej litery w ciągu. W obu oryginalnych gramatykach Rebera (1967, 1969) prawdopodobieństwo to wynosi zawsze 0,5. Gramatyka Vokeya i Brooksa generuje różne poziomy prawdopodobieństwa dla różnych stanów (0,5 lub 0,33). Analizowane kryterium dotyczy oczywiście jedynie gramatyk zbudowanych z użyciem automatu Markowa. Założono, że gramatyki o mniejszym prawdopodobieństwie pojawienia się danego stanu pozwalają na tworzenie ciągów o wyższych wskaźnikach losowości, a więc ciągi mniej sekwencyjne.

W przeprowadzonej analizie porównawczej wykorzystano zestawy ciągów wygenerowanych na podstawie opisanych powyżej gramatyk (analizie poddano zestawy ciągów wykorzystywanych w cytowanych pracach). Do celów analizy wskaźników losowości, ciągi wygenerowane z każdej z opisanych wcześniej gramatyk połą-

Tabela 1. Wyniki analizy losowości wybranych gramatyk stosowanych w zadaniach AGL. Wyższa wartość liczbową wskaźników oznacza większe odchylenie od losowości, co można interpretować, jako większą sekwencyjność ciągów wygenerowanych z gramatyki.

Gramatyka	Wskaźniki losowości		
	R	RNG	RNG2
REBER (1969), na podstawie Dienes i Scott (2005)	7,34	0,7	0,6
REBER (1967)	1,67	0,61	0,51
VOKEY & BROOKS (1992)	3,94	0,57	0,52
MATHEWS i in. (1989), gramatyka dwuwarunkowa.	0,25	0,37	0,36
PIOTROWSKI, STETTNER i WIERZCHON (2010), gramatyka niesekwencyjna.	0,09	0,39	0,38

czono zostały w jeden ciąg. Następnie obliczono wskaźniki R, RNG oraz RNG2. Szczegółowe wyniki przedstawione zostały w Tabeli 1.

Analizując kryterium prawdopodobieństwa wyboru kolejnych stanów w gramatykach, jako predykatora regularności, wydaje się, że najbardziej sekwencyjne powinny być gramatyki Rebera oraz Vokeya i Brooksa. Jednak wyniki uzyskane z wykorzystaniem wskaźników losowości nie pozwalają jednoznacznie stwierdzić, czy to kryterium jest takim predykatorem. Wprawdzie najmniej regularne okazały się ciągi nie oparte na sekwencyjnym aparacie Markowa, to jednak gramatyka Rebera (1967), której prawdopodobieństwo możliwości wyboru kolejnych stanów jest wysokie, uzyskała aż w dwóch wskaźnikach (R i RNG2) wartości niższe od bardziej nieprzewidywalnej gramatyki Vokeya i Brooksa.

Eksperyment 1. Porównanie poprawności klasyfikowania ciągów w sztucznych gramatykach i poziomu losowości.

Przywołane wcześniej wyniki badań w których wykorzystywano różne rodzaje gramatyk mają tę wadę, że pochodzą z odrębnych badań eksperymentalnych. Nie da się ich tak na prawdę porównać bezpośrednio, m. in. ze względu na różnice w procedurach badawczych (różna liczba ciągów prezentowanych w fazie uczenia, różna liczba powtórzeń ciągów, różne czasy prezentacji, etc). By móc odnieść wyniki analiz matematycznych wykorzystujących miary losowości do wskaźników behawioralnych, przeprowadziliśmy badania siły efektu uczenia mimowolnego na ciągach skonstruowanych według opisanych wcześniej pięciu gramatyk. Zgodnie z założeniem o probabilistycznej naturze uczenia się sztucznych gramatyk (Pothos, 2010), postawiliśmy hipotezę o istnieniu różnic w klasyfikacji, zależnych od rodzaju wykorzystanej gramatyki. Druga hipoteza mówiła o kierunku tych różnic i wiązała je z poziomem sekwencyjności: im bardziej sekwencyjna gramatyka, tym bardziej

przewidywalne ciągi można z niej wygenerować. A zatem klasyfikacja ciągów przez osoby badane powinna być tym trafniejsza, im mniej losowa jest gramatyka.

Osoby badane

W eksperymencie wzięło udział 76 osób, 64 kobiety i 8 mężczyzn (średnia wieku 23, odch. std = 2,4), wolontariuszy, studentów różnych kierunków Uniwersytetu Jagiellońskiego.

Materiały i aparatura

Osobom badanym prezentowano ciągi literowe stworzone według 5 różnych gramatyk. Dla gramatyki Rebera (1967 i 1969) wykorzystane zostały egzemplarze zamieszczone w pracy Dienesa i Scotta (2005). Egzemplarze zbudowane na podstawie gramatyki Vokeya i Brooksa – z ich artykułu (Vokey i Brooks, 1992). Ciągi skonstruowane wg gramatyki dwuwarunkowej oraz niesekwencyjnej zostały skonstruowane zbudowane według zasad przedstawionych na rys. 2. W fazie uczenia użyto 15 ciągów prezentowanych dwukrotnie w losowym układzie. W fazie klasyfikacji użyto 36 ciągów (18 gramatycznych, różnych od prezentowanych w fazie 1, oraz 18 niegramatycznych). W badaniach wykorzystano papierowe arkusze do klasyfikacji ciągów. Egzemplarze prezentowane były na ekranie za pomocą rzutnika multimedialnego w tempie 15s – zarówno w fazie uczenia się jak i klasyfikacji.

Procedura

Eksperyment składał się z dwóch części. W pierwszej, osoby badane były instruowane by starały się zapamiętać jak najwięcej ciągów. W drugiej części, osoby badane otrzymywały informację, że ciągi, których się uczyły były stworzone według pewnych reguł. Następnie proszono badanych by, określiły czy ciągi prezentowane kolejno w drugiej części są stworzo-

ne według tych samych reguł, według których tworzone były ciągi z pierwszej części, czy nie. Jeżeli uznają, że dany ciąg jest stworzony według reguł, mają wpisać w odpowiedniej rubryce arkusza „T”, jeśli uważają, że ciąg nie był stworzony według tych reguł – „N”. Osoby badane podzielono na 5 grup, każda z nich wykonywała takie samo zadanie, lecz z inną gramatyką.

Wyniki

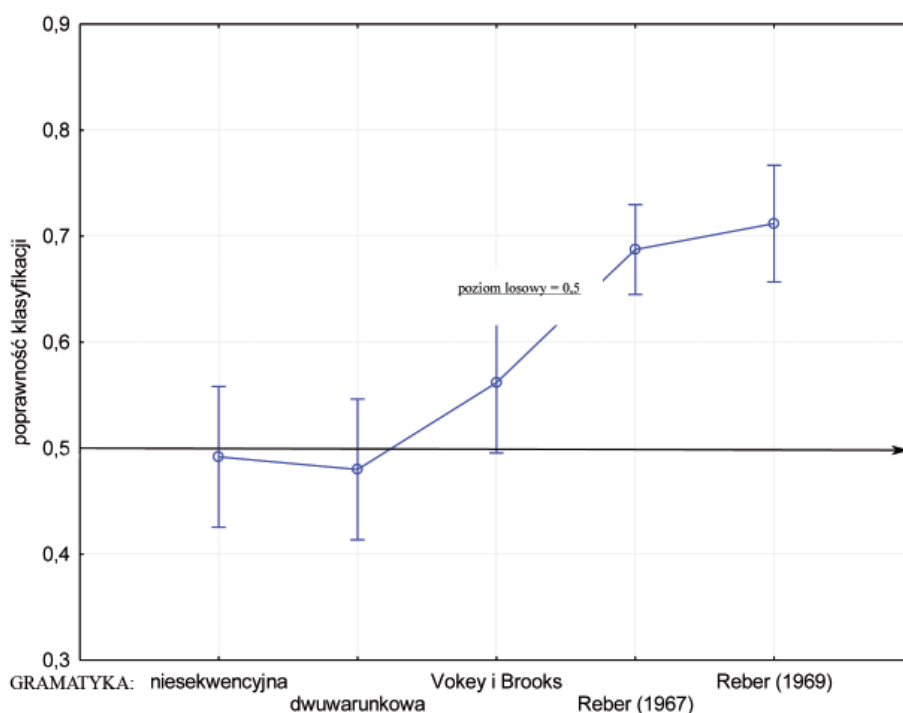
Wyniki poprawności klasyfikacji ciągów porównano w zależności od rodzaju gramatyk. Poprawności klasyfikowania w gramatyce niesekwencyjnej ($M=0,49$; $SD=0,07$) oraz w dwuwarunkowej ($M=0,48$; $SD=0,1$) nie przekroczyły poziomu losowego 0,5 (odpowiednio: $t=-0,36$; $p>0,7$; $t=-0,63$; $p>0,5$). Wyniki dla gramatyki Vokeya i Brooksa ($M=0,56$; $SD=0,07$) istotnie różniły się od poziomu losowego ($t=2,88$; $p<0,05$). Wyniki dla obu gramatyk: Rebera A (1967) i Rebera B (1969) wynosiły odpowiednio: $M_A=0,69$; $SD_A=0,09$; $M_B=$; $SD_B=$ i były istotnie wyższe od poziomu losowego (odpowiednio: $t_A=10,43$; $p<0,01$; $t_B=0,71$; $p<0,01$). Wyniki powyższe ilustruje rys. 3.

Efekty porównań między średnimi dla każdej z gramatyk zostały przedstawione w tabeli 2.

Korelacja między średnimi klasyfikowania ciągów i poziomu losowości dla wskaźnika R nie była istotna, dla wskaźników RNG i RNG2 była istotna ($p<0,5$) i wynosiła odpowiednio ($r=0,95$ i $r=0,90$).

Dyskusja wyników

Uzyskane wyniki klasyfikacji ciągów nie odbiegają od przytoczonych przykładów z literatury. Obie gramatyki nieoparte na łańcuchach Markowa zostały wyuczone najslabiej, a ich klasyfikacja nie różniła się od poziomu losowego. Mimo, że wyniki klasyfikacji w gramatyce Vokeya i Brooksa nie różniły się statystycznie od reguły niesekwencyjnej i dwuwarunkowej, to



Ryc. 3. Wyniki eksperymentu 1. Poprawność klasyfikacji ciągów dla różnych gramatyk.

Tabela 2. Porównania między wynikami klasyfikacji w zależności od rodzaju użytej gramatyki. Porównania zaplanowane metodą kontrastów.

istotność: ** $p < 0,01$	Reber A (1067)	Reber B (1969)	Vokey i Brooks	dwuwarunkowa
niesekwencyjna	$F_{1,71}=24,56^{**}$	$F_{1,71}=28,79^{**}$	n.i.	n.i.
dwuwarunkowa	$F_{1,71}=27,62^{**}$	$F_{1,71}=25,93^{**}$	n.i.	
Vokey i Brooks	$F_{1,71}=10,13^{**}$	$F_{1,71}=12,06^{**}$		
Reber B (1969)	n.i.			

sam fakt, że ciągi skonstruowane na podstawie takich reguł były klasyfikowane istotnie powyżej poziomu losowego (podobnie jak obie gramatyki Rebera), świadczy, że badani łatwiej uczyli się gramatyk sekwencyjnych. Wynik ten potwierdza

zatem pierwszą hipotezę. Analiza korelacji losowości i poprawności klasyfikacji wskazuje, że dwa spośród wybranych wskaźników losowości (RNG i RNG2) ściśle odpowiadają porządkowi gramatyk ustalonemu według efektywności

uczenia. Ten wynik zgodny jest z hipotezą drugą. Można zatem wnioskować, że istotnym czynnikiem wpływającym na uczenie się sztucznych gramatyk jest ich sekwencyjność. Badani nie byli w stanie nauczyć się gramatyk opartych na regułach innych niż sekwencyjne. Można to tłumaczyć odnosząc się do koncepcji uczenia się prawdopodobieństwa pojawienia się fragmentów ciągów czy też zbitek literowych. Jeśli bowiem w taki właśnie sposób reprezentowana jest wiedza o regułach gramatyki, to z ciągów, w których zbitki nie powtarzają się, nie można wywnioskować prawdopodobieństwa pojawienia się określonego fragmentu ciągu. Tworzenie zbitek elementów, uporządkowanych według pozycji, możliwe jest gdy mamy do czynienia z materiałem w naturalny sposób sekwencyjnym, jak litery czy cyfry. Jak jednak przebiegałoby uczenie gramatyk na materiale, który nie jest sekwencyjny (np. twarze)? Odpowiedź na to pytanie może zmodyfikować koncepcje reprezentacji wiedzy nabywanej w zadaniach AGL, opierane na znajdowaniu prawdopodobieństwa w sekwencji elementów.

Określanie sekwencyjności gramatyk, z wykorzystaniem wskaźników losowości jest metodą prostą, i jak wskazują wyniki, skuteczną. Szczególnie wskaźnik RNG okazał się najbardziej trafny. Wprowadzenie kryterium sekwencyjności, związane bezpośrednio z siłą efektu uczenia mimowolnego, pozwoli na porównywanie gramatyk między sobą, np. by dobrać najbardziej odpowiednie gramatyki do eksperymentów, lub jako źródło interpretacji uzyskanych wyników.

LITERATURA CYTOWANA

- Altmann, G.T.M., Dienes, Z. i Goode, A. (1995). Modality independence of implicitly learned grammatical knowledge. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 21, 899-912.
- Barbasz, J., Stettner, Z., Wierchoń, M., Piotrowski, K. T. i Barbasz, A. (2008). How to estimate the randomness in random sequence generation task? *Polish Psychological Bulletin*, 39(1), 42-46.
- Brooks, L. R. (1978). Nonanalytic concept formation and memory for instances. In E. Rosch i B. B. Lloyd (red.), *Cognition and Categorization* (pp. 170-211). Hillsdale, NJ: Erlbaum.
- Cock, J. (2005). Completely ruled out? Using response time data to investigate biconditional artificial grammar learning. *European Journal of Cognitive Psychology*, 17 (6), 770-784
- Dienes, Z. i Scott, R. (2005). Measuring unconscious knowledge: distinguishing structural knowledge and judgment knowledge. *Psychological Research*, 69, 338-351
- Evans, F. J. (1978). Monitoring attention deployment by random number generation: An index to measure subjective randomness. *Bulletin of the Psychonomic Society*, 12, 35-38.
- Friedman, N.P. i Miyake, A. (2004). The relations among inhibition and interference cognitive functions: A latent variable analysis. *Journal of Experimental Psychology: General*, 133, 101-135.
- Knowlton, B. J. i Squire, L. R. (1996). Artificial grammar learning depends on implicit acquisition of both abstract and exemplar-specific information. *Journal of Experimental Psychology. Learning, Memory & Cognition*, 22, 169-181.
- Mathews, R. C, Buss, R. R., Stanley, W. B., Blanchard-Fields, F., Cho, J. R., i Druhan, B. (1989). The role of implicit and explicit processes in learning from examples: A synergistic effect. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 15, 1083-1100.
- Miyake, A., Witzki, A. H. i Emerson, M. J. (2001). Field dependence-independence from a working memory perspective: a dual task investigation of the Hidden Figure Test. *Memory*, 9,(4,5,6), 445-457.
- Perruchet P. i Pacteau C. (1990). Synthetic grammar learning: implicit rule abstraction or explicit fragmentary knowledge? *Journal of Experimental Psychology: General*, 119, 264-275
- Perruchet, P. (2008). Implicit learning. In: J. H. Byrne i H. L. Roediger III (red.), *Learning and memory: A comprehensive reference: Vol. 2. Cognitive psychology of memory*, Oxford, England: Elsevier, 597-621.
- Piotrowski, K.T., Stettner, Z. i Wierchoń, M. (2010). *Transfer of prior knowledge in implicit learning*. XIV Conference of Association of the Scientific Study of Consciousness. Toronto, 24-28.06.2010

- Piotrowski, K.T., Stettner, Z. Wierzchoń, M. (2011). *Hidden rules in AGL task*. Meeting at Laboratory of Applied Psychology. Cognition, Emotion and Decision making. Sopot. 18.11.2011
- Pothos, E.M. i Bailey, T.M. (2000). The role of similarity in artificial grammar learning. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 26(4), 847-862.
- Pothos, E.M. (2007). Theories of Artificial Grammar Learning. *Psychological Bulletin*, 2 (133), 227–244
- Pothos, E.M. (2010) An entropy model for artificial grammar learning. *Frontiers in Cognitive Science*, 1:16. doi: 10.3389/fpsyg.2010.00016
- Reber, A. S. (1967). Implicit learning of artificial grammars. *Journal of Verbal Learning and Verbal Behaviour*, 5, 855-863.
- Reber, A. S. (1969). Transfer of syntactic structure in synthetic languages. *Journal of Experimental Psychology*, 81, 115-119.
- Reber, A. S. (1989). Implicit learning and tacit knowledge. *Journal of Experimental Psychology: General*, 118, 219-235
- Reber, A.S. i Allen, R. (1978). Analogy and abstraction strategies in synthetic grammar learning: A functionalist interpretation. *Cognition*, 6, 189-221.
- Reber, A.S., Walkenfeld, F.F. i Hernstadt, R. (1991). Implicit and explicit learning: Individual differences and IQ. *Journal of Experimental Psychology: Learning, Memory, and Cognition*. 17(5), 888-896.
- Servan-Schreiber, E. i Anderson, J.R. (1990). Learning artificial grammars with competitive chunking. *Journal of Experimental Psychology: Learning, Memory, and Cognition*. 16(4), 592-608.
- Towse, J.N. (1998). On random generation and the central executive of working memory. *British Journal of Psychology*, 89(1), 77-101.
- Towse, J. N. i Neil, D. (1998). Analyzing human random generation behavior: A review of methods used and a computer program for describing performance. *Behavior Research Methods, Instruments & Computers*, 30(4), 583-591.
- Tunney R. J. i Altmann G. T. M. (2001). Two models of transfer in artificial grammar learning. *Journal of Experimental Psychology: Learning, Memory, and Cognition*. 27, 614–639.
- Vokey, J. R., i Brooks, L. R. (1992). Salience of item knowledge in learning artificial grammar. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 20, 328–344.

Krzysztof T. Piotrowski

Institute of Psychology, Jagiellonian University
Teacher Training Center, Jagiellonian University;

Michał Wierzchoń

Institute of Psychology,
Jagiellonian University

Zbigniew Stettner

Institute of Psychology,
Jagiellonian University

EVALUATING SEQUENTIALITY OF ARTIFICIAL GRAMMARS

ABSTRACT

When carrying out experiments on implicit learning in artificial grammar learning paradigm researchers often develop and use new grammars. However, they do not necessarily pay attention to the relations between applied set of rules and effectiveness of the learning procedure. Here, we discuss the theoretical and methodological consequences of the relations' analysis for implicit learning studies. We propose and present results of sequentiality analysis by which six different grammars were compared. To assess the sequentiality of grammars, methodology of randomness assessment taken from random number generation studies was used. We observed differences in sequentiality between grammars, suggesting that this parameter should be taken in to the account when the artificial grammar experiments are planned.

Key words: implicit learning, artificial grammars, sequentiality, randomness assessment