

Tomasz Przybyła

Uniwersytet im. Adama Mickiewicza w Poznaniu
tomekprzybyla@gmail.com
ORCID: 0000-0002-8309-6559

Maria Duszczyk

Uniwersytet im. Adama Mickiewicza w Poznaniu
marysia.duszczyk@gmail.com
ORCID: 0000-0001-6724-4067

Agnieszka Kruszwicka

Uniwersytet im. Adama Mickiewicza w Poznaniu
a.kruszwicka@gmail.com
ORCID: 0000-0001-7834-2316

Weronika Rochatka

Uniwersytet im. Adama Mickiewicza w Poznaniu
weronikarochatka@gmail.com
ORCID: 0000-0003-3202-7040

Michał Klichowski

Uniwersytet im. Adama Mickiewicza w Poznaniu
klichowski.michal@gmail.com
ORCID: 0000-0002-1614-926X

Zastosowania neurofeedbacku w edukacji matematycznej: eksperyment SpeedMath z udziałem uczniów wyższych klas szkoły podstawowej


Wprowadzenie

Biofeedback, czyli biologiczne sprzężenie zwrotne, to proces, w wyniku którego jednostka otrzymuje informacje (najczęściej w formie wizualnej lub dźwiękowej) o swoim stanie fizjologicznym. Osoba pozyskująca takie dane ma możliwość ćwiczenia samokontroli, a tym samym zwiększenia własnej wydajności poznawczej. Obecnie rynek konsumencki oferuje wiele różnych urządzeń (np. smartwatche czy aplikacje mobilne) monitorujących aktywność fizjologiczną m.in. w zakresie

częstotliwości oddechu, aktywności elektrycznej mięśni, zawartości tlenu we krwi czy jakości snu (Peake i in., 2018). Bardziej zaawansowanych danych, dotyczących konkretnie aktywności mózgu, dostarcza natomiast neurofeedback, a w szczególności biofeedback EEG. Elektroencefalografia (EEG), czyli metoda badania czynności elektrycznej mózgu, umożliwia bowiem jej zarejestrowanie, a co za tym idzie, rozpoznanie wzorców bioelektrycznych aktywności mózgu charakterystycznych dla danego stanu, czyli fal mózgowych (delta, theta, alfa, beta, gamma) (Marzbani i in., 2016). W związku z tym neurofeedback szeroko stosowany jest m.in. w praktyce medycznej, neurologicznej czy psychoterapeutycznej (Kirk, 2015). Używa się go w leczeniu chorób, terapii zaburzeń i w procesie rehabilitacji, np. aby zredukować ból w przypadku uszkodzenia rdzenia kręgowego (Vuckovic i in., 2019), usprawnić funkcjonowanie emocjonalne i społeczne osób z zaburzeniami ze spektrum autyzmu (Goodman i in., 2018), obniżyć reakcje lękowe będące objawem zespołu stresu pourazowego (Chiba i in., 2019) czy zmniejszyć nasilenie napadów w przypadku epilepsji (Reddy, Sneha, 2019). Jednak równie istotne jest ujęcie neurofeedbacku jako procesu samoregulacji, obejmującego konkretne etapy, umożliwiającego zdrowej jednostce zwiększenie kontroli nad aktywnością mózgu i dającego jej tym samym szansę poprawy funkcji poznawczych oraz modulowania zachowania (Enriquez-Geppert i in., 2017). W tym kontekście mówić można więc o treningu, będącym procesem uczenia się przez doświadczenie, w którym dostrzec można pewne podobieństwa do mechanizmów warunkowania klasycznego i instrumentalnego (Demos, 2019). Za przykład uzmysławiający potencjał takiego procesu posłużyć mogą wyniki badań nad treningiem matematycznym, które dowodzą, że neurofeedback sprzyja rozwojowi kompetencji matematycznych (Sadudeemeechithaweechoke i in., 2017). Co warto podkreślić, ta sama zależność dotyczy także osób ze specyficznymi trudnościami w uczeniu się, w tym trudnościami w uczeniu się matematyki (Hashemian, Hashemian, 2015; Sittiprapaporn, Chang, 2019).

Istnieje wiele narzędzi stosowanych w procedurach neurofeedbacku. W przeciwieństwie do tradycyjnych aparatów EEG, są one mobilne, tanie (zarówno w zakupie, jak i eksploatacji), łatwe w użyciu (ze względu na wzmacniacze w elektrodach, nie trzeba używać specjalnego żelu przewodzącego, a ich sztywna konstrukcja eliminuje konieczność stosowania czepka), a ponadto można je używać nie tylko w specjalnym laboratorium, a w zasadzie wszędzie (Sawangjai i in., 2019; Huang i in., 2020). To wszystko sprawia, że wykorzystuje się je zarówno w gabinetach terapeutycznych, jak i w rzeczywistości szkolnej, także z udziałem wielu uczniów jednocześnie (Xu, Zhong, 2018; Huang i in., 2020). I choć nie są pozbawione wad (Ratti i in., 2017; Huang i in., 2020), to pozwalają na szybkie uzyskanie informacji o pracy mózgu w bezpieczny sposób (Xu, Zhong, 2018), wykazując przy tym wysoką rzetelność zbierania danych, porównywalną do tradycyjnych aparatów EEG (Zerafa i in., 2018; Kam i in., 2019; Hinrichs i in., 2020). Na rynku biofeedbacku znaleźć można takie narzędzia, jak EPOC Emotive, Muse InteraXon, ENOBIO 8 Neuroelectrics, BR8

BRI, Quick Cognionics, OpenBCI (Górska, Olszewski, 2015; Sawangjai i in., 2019; Huang i in., 2020; LaRocco i in., 2020). Jednak najpopularniejszym jest rozwijany od 2007 roku MindWave NeuroSky (Xu, Zhong, 2018; Sawangjai i in., 2019). Jak ukazaliśmy na ryc. 1, liczba elektrod została w nim zredukowana do jednej, pobierającej sygnały elektryczne z czoła w podstawowej lokalizacji (Fp1) oraz drugiego czujnika kontrolnego w postaci klipsa przypinanego do podstawowego punktu referencyjnego (A1), czyli do płatka lewego ucha (Sawangjai i in., 2019). Pobierany sygnał, wzmacniony przez urządzenie 8 tys. razy, przekazywany jest do komputera lub aplikacji za pomocą modułu Bluetooth, gdzie podlega analizie (Górska, Olszewski, 2015; LaRocco i in., 2020). MindWave głównie wykorzystywany jest do pomiaru koncentracji (na podstawie fal beta >14 Hz) i relaksacji (na podstawie fal alpha 8–14 Hz), które przeliczane są za pomocą algorytmów eSense na wyniki ukazywane w skali od 0 do 100, gdzie wartości od 0 do 20 oznaczają poziom mocno obniżony, od 20 do 40 – obniżony, od 40 do 60 – neutralny, od 60 do 80 – nieznacznie podwyższony, a od 80 do 100 – podwyższony (Sałabun, 2014; Przybyła, Klichowski, 2018a).



Ryc. 1. Budowa i działanie MindWave. Urządzenie MindWave zbudowane jest z dwóch suchych elektrod – pierwszej umieszczonej na czole w pozycji Fp1 (według międzynarodowego systemu 10–20 rozmieszczenia elektrod) i drugiej w postaci klipsa zapinanego w pozycji A1. Różnica rejestrowanych przez nie potencjałów elektrycznych stanowi jednokanałowy sygnał EEG, który następnie jest wzmacniany, filtrowany, próbkowany, a w końcu analizowany przez odpowiednie algorytmy

Choć współcześnie prowadzi się szereg badań dotyczących interfejsów komputer-maszyna (BCI – *brain-computer interface*) (Kounte i in., 2020), te dotyczące MindWave nie są liczne i dotyczą dość rozproszonych jego zastosowań. Wykazano w nich, że MindWave zapewnia osobom niepełnosprawnym efektywne sterowanie wózkiem inwalidzkim (Cheng i in., 2018) i daje im szansę na wydajną obsługę inteligentnego domu (*smart home*) (Qin i in., 2020), a jednostkom cierpiącym na

porażenie mózgowe – sprawne korzystanie z komputera (Molina-Cantero i in., 2017). Ponadto udowodniono, że użytkowanie MindWave zwiększa bezpieczeństwo pojazdów z autopilotem w sytuacjach awaryjnych (Bindhu, 2020).

Jednak z perspektywy prowadzonych przez nas rozważań najistotniejsze są badania nad zastosowaniem MindWave w kontekście edukacyjnym. W takich studiach mierzono na przykład poziom skoncentrowania podczas uczenia się z wykorzystaniem urządzeń mobilnych (*m-learning*) (Ni i in., 2020) czy w trakcie uczenia się w cyberparkach, czyli hybrydowych przestrzeniach łączących naturę i technikę (Klichowski, 2017). W innych badaniach tworzono eksperymentalne systemy uczenia się, w których osiągnięcie odpowiedniego – mierzonego poprzez MindWave – stanu umysłu (np. w zakresie poziomu koncentracji) umożliwiało uczącym się przejście do następnej lekcji (Tabakcioğlu i in., 2016). W kontekście edukacji matematycznej wykazano, że trening wykonywania zadań arytmetycznych w czasie rzeczywistym (*the real-time arithmetic recognition task*) wspomagany MindWave podnosi u osób dorosłych efektywność w zakresie szybkości, pamięci, koncentracji, elastyczności i rozwiązywania problemów (Sadudeemeechaithawechoke i in., 2017). Taki sam wniosek płynie z bardzo podobnego badania przeprowadzonego z udziałem dzieci z trudnościami w uczeniu się (Sittiprapaporn, Chang, 2019). Niestety badań poświęconych treningowi matematycznemu z użyciem MindWave (i szerzej: związanych z zastosowaniem technologii EEG w edukacji matematycznej) jest szczególnie niewiele. Ponadto, te nieliczne studia mają wiele ograniczeń. Najczęściej były one bowiem prowadzone z udziałem niewielkiej liczby uczestników, w nienaturalnych warunkach, sprawdzały tylko ograniczone aspekty poznawcze i skupiano się w nich głównie na ocenie poziomu uwagi/koncentracji i medytacji/relaksacji uczestników, nie dokonując porównań tych danych z innymi cechami badanych (Xu, Zhong, 2018). Tym samym, trudno jest określić poziom skorelowania neuroparametrów dostarczanych przez MindWave z „realnymi” atrybutami uczących się matematyki, a w konsekwencji ocenić potencjał stosowania neurofeedbacku w edukacji matematycznej. Jaki byłby bowiem jego sens, gdyby tego typu parametry okazały się jedynie nieskorelowanymi z rzeczywistością artefaktami?

W tym projekcie postanowiliśmy zatem sprawdzić, czy dane (neuroparametry) generowane przez MindWave podczas wykonywania zadań arytmetycznych (w przypadku naszego eksperymentu były to ćwiczenia zaimplementowane w grę SpeedMath) są skorelowane z różnymi cechami poznawczymi ucznia czy innego typu danymi dotyczącymi jego funkcjonowania umysłowego. Postawiliśmy hipotezę, że średnia wysoka koncentracja podczas wykonywania zadania matematycznego czy umiejętność jej kontrolowania podczas takiego zadania, stanowiące rdzeń neuroanalityczny arytmetycznego treningu biofeedback EEG, powinny korelować z małą liczbą błędów dokonywanych podczas obliczeń, czy z ogólnymi dobrymi kompetencjami matematycznymi, a także z wysokimi wskaźnikami umiejętności koncentrowania się obliczonymi innymi – nie opartymi na EEG – metodami. I *vice*

versa. Uzyskane przez nas wyniki okazały się bardzo zaskakujące i rzucają nowe światło na to, który z parametrów generowanych przez MindWave warto wykorzystywać w rzeczywistości edukacyjnej, jeśli neurofeedback ma stać się efektywną formą technologicznego wspomaganie dydaktyki matematyki.

1. Metody

1.1. Uczestnicy

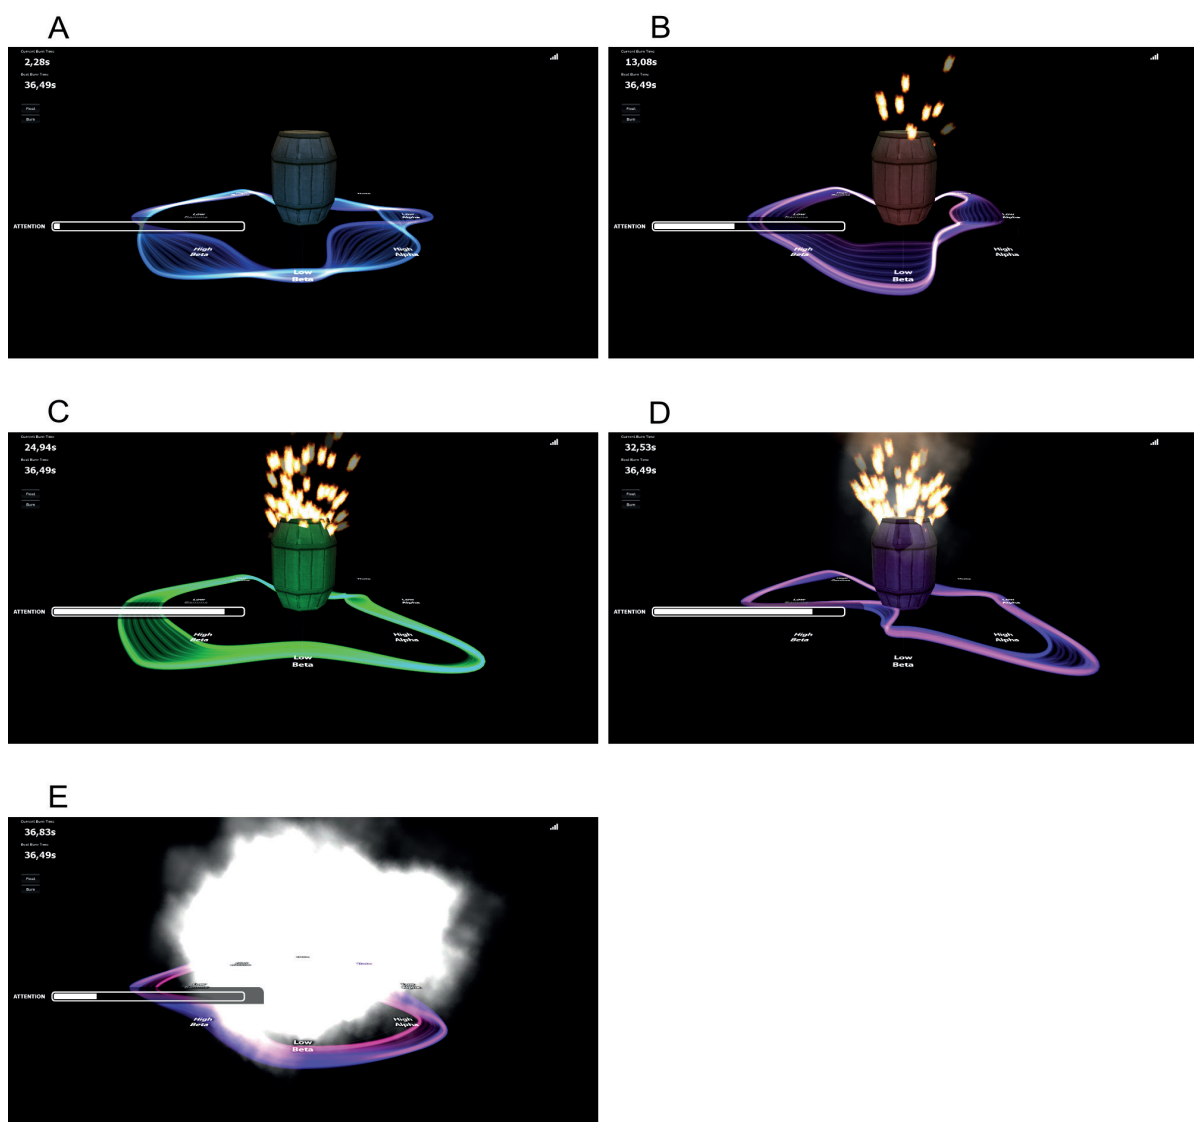
Dwudziestu zdrowych ochotników ($N = 20$), uczniów 6 klasy państwowej szkoły podstawowej w wieku 11–13 lat (średni wiek = 12.00 lat, odchylenie standardowe [SD] = 0.32), wzięło udział w eksperymencie. Połowę badanych stanowiły dziewczynki. Uczniowie przybywali do naszego laboratorium wraz z nauczycielem wychowawcą. Przed badaniem przedstawiliśmy każdemu uczniowi i wychowawcy szczegółowy przebieg eksperymentu. Wzrok każdego z badanych był normalny lub skorygowany do normalnego. Żaden z uczestników nie miał historii zaburzeń neurologicznych czy deficytów poznawczych.

1.2. Procedura

Badanie odbyło się w listopadzie 2019 roku w laboratorium działającym przy Pracowni Badań nad Procesem Ucznia się Uniwersytetu im. Adama Mickiewicza w Poznaniu (*Learning Lab*). Po przybyciu do laboratorium przeprowadzany był krótki wywiad z uczniem. Pytaliśmy o rok urodzenia oraz o ocenę z matematyki otrzymaną na koniec poprzedniego roku szkolnego, czyli na świadectwie ukończenia 5 klasy. W tym czasie wychowawca wypełniał kwestionariusz, w którym miał ocenić (poprzez pięciostopniową skalę, w której 1 oznaczało „bardzo nisko”, 2 – „nisko”, 3 – „przeciętnie”, 4 – „wysoko”, 5 – „bardzo wysoko”) ogólną umiejętność swojego ucznia w zakresie koncentrowania się na różnych zadaniach oraz jego ogólne kompetencje matematyczne. Uczeń nie mógł poznać odpowiedzi udzielonych przez nauczyciela.

Kolejnym krokiem procedury było umieszczenie na głowie badanego elektroencefalografu MindWave Mobile EEG (NeuroSky, Silicon Valley, CA, USA) i skonfigurowanie go. Następnie uczeń wykonywał pierwsze zadanie, siedząc przy stole na standardowym krześle z oparciem, na którym znajdował się laptop Latitude 5590 1,8 GHz (Dell Inc., Round Rock, TX, USA). Ekran tego komputera ustawiony był 57 centymetrów od oczu uczestnika, a zatem w pozycji wzrokowo optymalnej (Klichowski i in., 2020). Zadanie polegało na zagranie w grę, uruchomioną na tym laptopie, będącą częścią oprogramowania Brainwave Visualizer 2.0 (NeuroSky, Silicon Valley, CA, USA), w której wyświetlana na ekranie beczka zaczyna płonąć, gdy

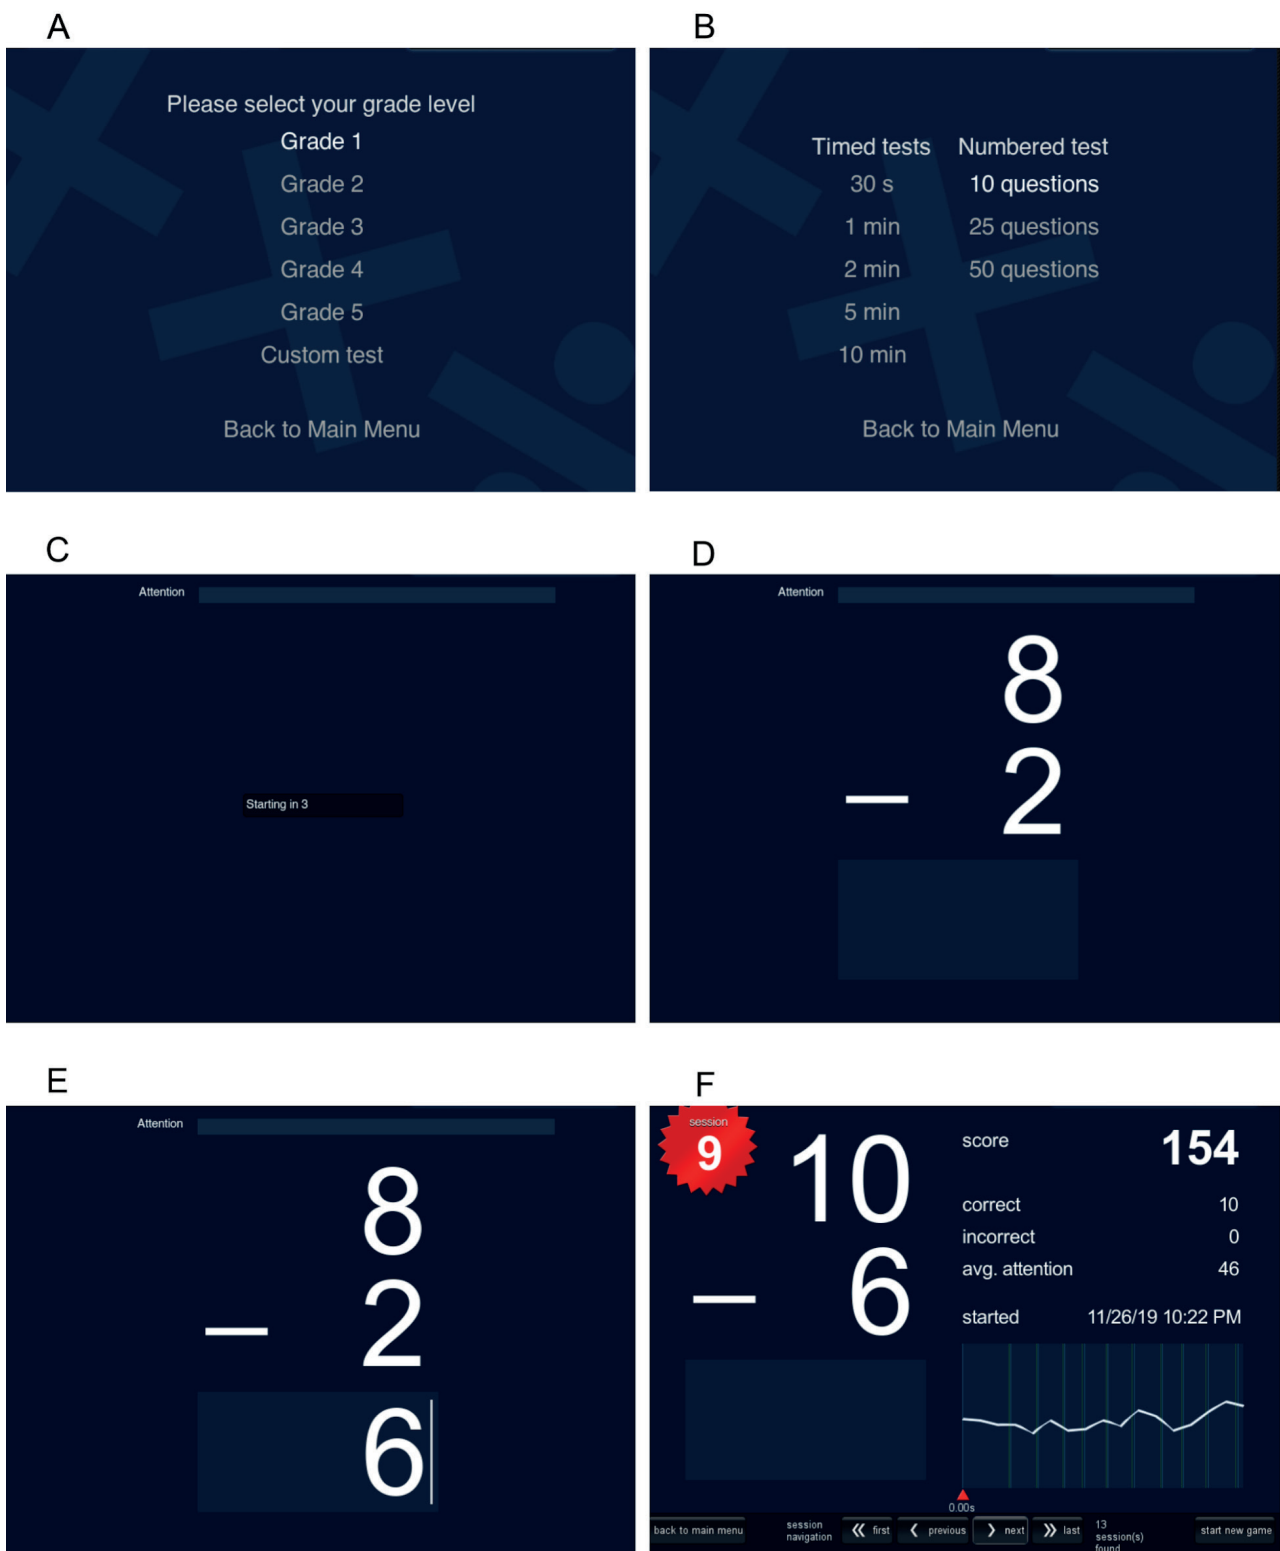
wzrasta – mierzona poprzez opisany we wstępie rozdziału algorytm eSense Attention Meter (NeuroSky, Silicon Valley, CA, USA) – koncentracja. Gdy badany uzyska wysoki poziom koncentracji i utrzyma go przez chwilę, beczka wybucha. Program rejestruje czas, jaki potrzebował uczestnik do wysadzenia beczki. Każdy uczestnik wykonywał to zadanie dwa razy. Pierwszy raz był treningowy, umożliwiającą uczniowi oswojenie się ze sprzętem EEG, drugi natomiast eksperymentalny. Zadanie to traktowaliśmy jako pomiar kontrolny, pozwalający pozyskać parametr inny niż związany z zadaniem eksperymentalnym, a więc matematycznym, ale ukazujący w jakimś sensie zdolność ucznia do panowania nad własnym skoncentrowaniem. Na ryc. 2 umieszczono kilka screenshotów z tej gry, pokazujących jej fazy.



Ryc. 2. Etapy gry oprogramowania Brainwave Visualizer 2.0, stanowiącej zadanie kontrolne eksperymentu. (A) Badanemu wyświetlona zostaje beczka – początek gry. (B) Gracz zaczyna koncentrować się na beczce – pojawiają się pojedyncze iskrzy. (C) Wzrost poziomu koncentracji badanego – więcej iskier, delikatnie widoczny dym. (D) Wysoki, ale jeszcze nie stały poziom koncentracji – dużo iskier, większa ilość dymu. (E) Wysoki, stały poziom koncentracji – eksplozja beczki

Po zakończeniu zadania treningowego rozpoczynała się docelowa faza procedury. Uczeń – nadal siedząc przy laptopie – zaczynał grać w SpeedMath. W grę zaimplementowane są różnego typu zadania matematyczne, takie jak obliczenie wartości sumy, różnicy, iloczynu lub ilorazu dwóch wartości liczbowych. Można w niej wybrać pięć poziomów trudności, gdzie pierwszy oznacza najłatwiejszy, a ostatni – najtrudniejszy. Po określeniu poziomu trudności trzeba wskazać jeden z dwóch wariantów rozgrywki. Pierwszy polega na tym, by rozwiązać jak największą liczbę zadań w czasie 30 sekund lub 1, 2, 5 lub 10 minut. Drugi – by rozwiązać daną liczbę zadań (10, 25 lub 50 ćwiczeń) jak najszybciej. Po wyborze danego typu ćwiczenia, należy spersonalizować trudność zadań. By to zrobić, wybiera się zakres liczb, na których dokonywane będą obliczenia (w przedziale od 1 do 1000) oraz określa spektrum wyświetlanych przykładów (dodawanie, odejmowanie, mnożenie, dzielenie; możliwe jest wytypowanie od 1 do 4 kategorii działań). Na potrzeby naszego eksperymentu wybraliśmy w SpeedMath poziom 1 (najłatwiejszy), złożony z 10 zadań na dodawanie i odejmowanie dwóch liczb w zakresie 20 (w niektórych próbach występowało przekraczanie progu dziesiętkowego). Te obliczenia uczestnik wykonywał w pamięci, a wynik wpisywał za pośrednictwem klawiatury numerycznej komputera. Gdy badany podał poprawny wynik, program uruchamiał kolejną próbę, a w przypadku błędnej odpowiedzi próba była powtarzana, aż uczeń podał wynik poprawny. Po prawidłowym wyliczeniu 10 zadań na ekranie komputera wyświetlała się liczba popełnionych błędów oraz wartość średniej koncentracji.

SpeedMath analizuje także poziom kontrolowania koncentracji. Im uczestnik utrzymuje dłużej koncentrację na stabilnym i relatywnie wysokim poziomie, tym otrzymuje więcej punktów (liczba uzyskanych punktów również wyświetla się na ekranie końcowym). Tym samym, jeśli u kogoś występuje wysoki średni poziom koncentracji, niekoniecznie otrzyma dużo punktów, bowiem jego koncentracja może falować, być czasem bardzo wysoka, a czasem niska (a więc przejawiać dużą dynamikę), co oznacza, że występuje tu problem z kontrolowaniem koncentracji. Inna osoba może mieć średnią koncentrację nie aż tak wysoką, ale otrzymać dużo punktów – dynamika koncentracji może być u niej bowiem bardzo niska, a więc umiejętnie utrzymuje koncentrację na stałym – choć nie najwyższym – poziomie podczas wykonywania zadań matematycznych. Celem neurofeedbacku jest nie tylko nauczenie klienta wywoływania zwiększonej koncentracji, ale także kontrolowania procesów poznawczych. SpeedMath nalicza więc punkty za zarządzanie koncentracją. Ostatecznym celem takich gier, jak SpeedMath, a szerzej – neurofeedbacku, jest wykształcenie umiejętności utrzymywania koncentracji na wysokim poziomie. W procesie nabywania tej kompetencji nagradzane są więc zarówno wzrosty koncentracji, jak i wszelkie przejawy jej kontrolowania. Innymi słowy, SpeedMath pozwala poznać dwa neuroparametry – średnią koncentrację podczas wykonania zadania, wyrażoną standardowymi wartościami od 0 do 100 oraz poziom kontroli koncentracji w formie zebranych punktów. Na ryc. 3 umieszczono kilka screenshotów z gry SpeedMath, ukazujących jej przebieg i wyświetlane elementy.



Ryc. 3. Fazy gry SpeedMath. (A) Wybór poziomu trudności. (B) Określenie wariantu rozgrywki. (C) Odliczanie wsteczne czasu do rozpoczęcia gry. (D) Przykładowe zadanie na obliczanie wartości różnicy. (E) Przykładowe zadanie uzupełnione o wynik różnicy. (F) Zakończenie gry – poinformowanie gracza o uzyskanych wynikach

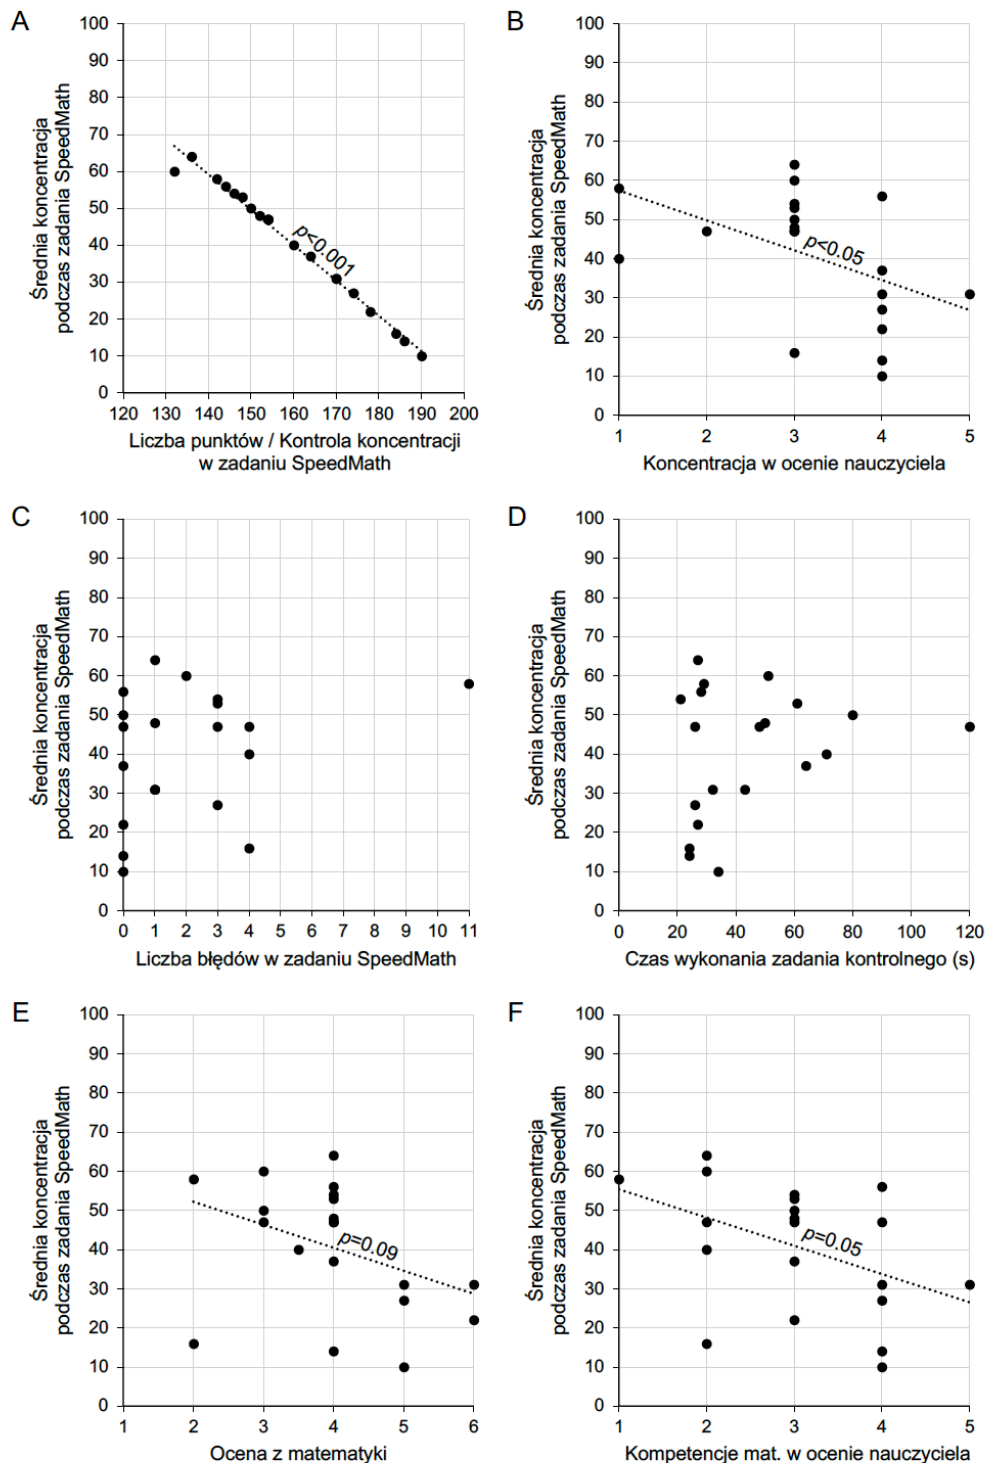
1.3. Statystyczna analiza danych i wizualizacja sieci

Wszystkie analizy statystyczne zostały przeprowadzone z użyciem IBM SPSS Statistics for Mac w wersji 26 (IBM Corp., Armonk, NY, USA) na komputerze iMac 1,4 GHz (Apple Inc., Cupertino, CA, USA). W analizach uwzględniono takie zmienne ilościowe, jak poziom koncentracji (wartości od 0 do 100), liczba punktów (poziom kontroli koncentracji) i błędów w zadaniu SpeedMath, czas wykonania zadania kontrolnego (wyrażony w sekundach [s]), ocena z matematyki (wyrażona liczbowo), nauczycielska ocena koncentracji i kompetencji matematycznych ucznia (w skali od 1 do 5), a także zmienną nominalną: płeć badanego (chłopiec, dziewczynka). W analizach korelacji wykorzystaliśmy współczynnik korelacji r -Pearsona (r), natomiast w analizach różnic Test- t dla prób niezależnych (t). Przyjęty poziom istotności wynosił $\alpha = 0,05$ (p). Do wizualizacji sieci użyto Gephi 0.9.2 (Gephi Consortium, Paris, France) i komputera MacBook Pro 2.7 GHz (Apple Inc., Cupertino, CA, USA). Za wagi połączeń pomiędzy węzłami sieci przyjęto wartość r .

2. Wyniki

2.1. Korelacja średniej koncentracji mierzonej MindWave i innych parametrów

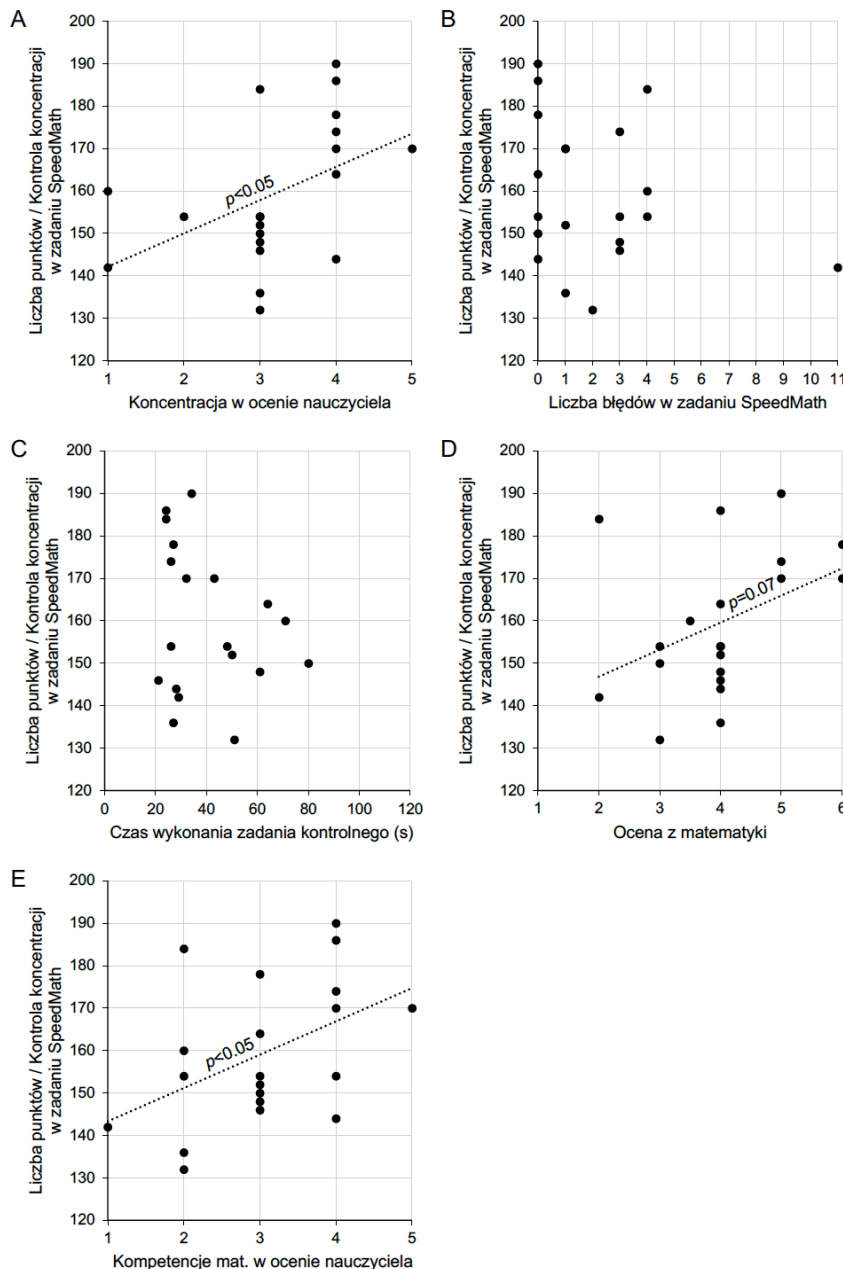
Jak zobrazowano na ryc. 4, analizy korelacji wykazały, że poziom średniej koncentracji podczas wykonywania zadania SpeedMath nie był skorelowany z liczbą błędów popełnionych w tym zadaniu ($r = 0.28$, $p = 0.24$, ryc. 4C), a także z czasem wykonania zadania kontrolnego ($r = 0.23$, $p = 0.32$, ryc. 4D). Parametr ten był natomiast istotnie skorelowany z liczbą punktów (kontrolą koncentracji) w zadaniu SpeedMath ($r = -0.99$, $p < 0.001$, ryc. 4A) oraz poziomem koncentracji określonym przez nauczyciela ($r = -0.47$, $p = 0.04$, ryc. 4B). Ponadto, dla pozostałych dwóch parametrów zaobserwowaliśmy wyraźny trend. W przypadku oceny z matematyki z poprzedniego semestru wartość p była bliska 0.09 ($r = -0.39$, ryc. 4E), natomiast jeśli idzie o nauczycielską ocenę kompetencji matematycznych p było równe przyjętej granicy dla poziomu istotności ($r = -0.44$, ryc. 4F). Wszystkie te korelacje i trendy były jednak negatywne, a zatem wysokim średnim poziomom koncentracji towarzyszyły niskie wartości tych czterech parametrów, z kolei niskim – wysokie. Wynik ten jest bardzo zaskakujący, gdyż pokazuje, że określony narzędziami neurofeedbacku poziom skoncentrowania na zadaniu matematycznym tak naprawdę nie odzwierciedla różnorodnie mierzonych wyróżników ucznia.



Ryc. 4. Korelacja średniej koncentracji mierzonej MindWave i innych parametrów. (A) Średnia koncentracja jest negatywnie skorelowana z kontrolą koncentracji. (B) Średnia koncentracja jest negatywnie skorelowana z koncentracją ocenianą przez wychowawcę. (C) Średnia koncentracja nie jest skorelowana z liczbą popełnianych błędów. (D) Średnia koncentracja nie jest skorelowana z czasem wykonania zadania. (E) Średnia koncentracja jest negatywnie skorelowana z ocenami z matematyki. (F) Średnia koncentracja jest negatywnie skorelowana z ocenami kompetencji matematycznych formułowanymi przez wychowawcę

2.2. Korelacja poziomu kontrolowania koncentracji mierzonej MindWave i innych parametrów

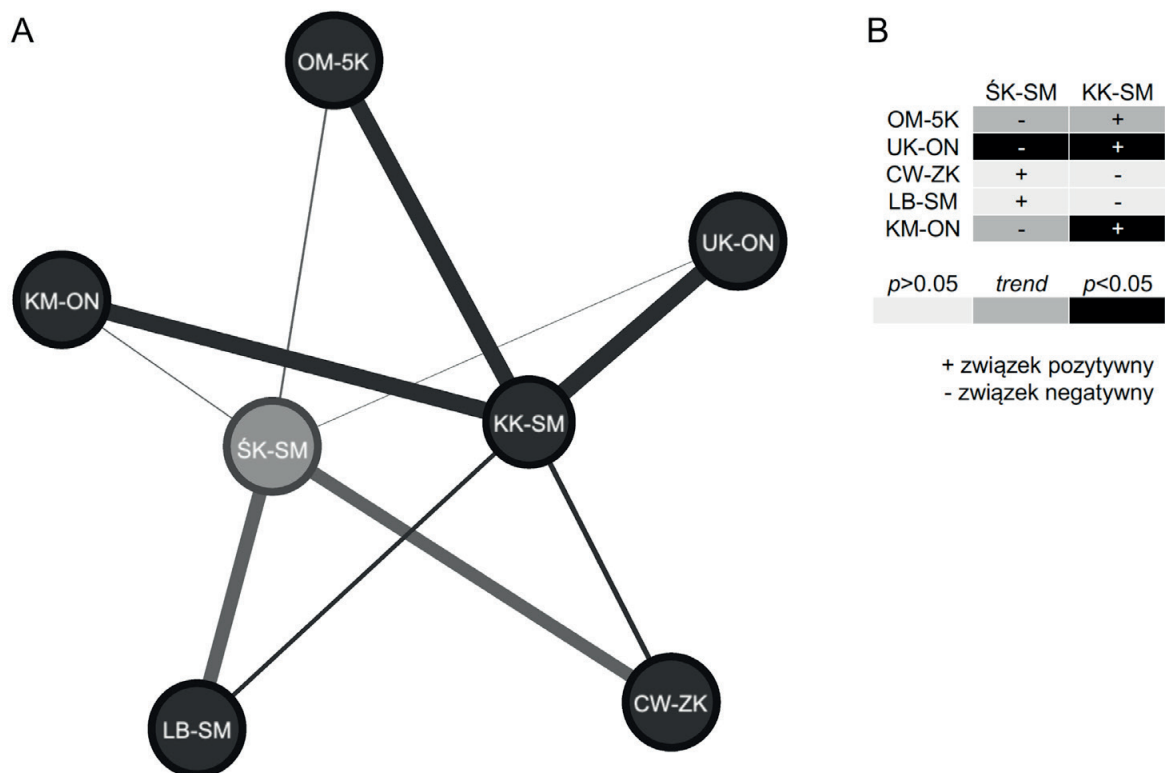
Odmienne wyniki uzyskaliśmy w analizach skorelowania poziomu kontroli koncentracji (wyrażonej w liczbie punktów uzyskanych w zadaniu SpeedMath). Parametr ten nie był skorelowany z liczbą błędów popełnionych w zadaniu Speed-



Ryc. 5. Korelacja poziomu kontrolowania koncentracji mierzonej MindWave i innych parametrów. (A) Kontrola koncentracji jest pozytywnie skorelowana z koncentracją ocenianą przez wychowawcę. (B) Kontrola koncentracji nie jest skorelowana z liczbą popełnianych błędów. (C) Kontrola koncentracji nie jest skorelowana z czasem wykonania zadania. (D) Kontrola koncentracji jest pozytywnie skorelowana z ocenami z matematyki. (E) Kontrola koncentracji jest pozytywnie skorelowana z ocenami kompetencji matematycznych formułowanymi przez wychowawcę

Math ($r = -0.27, p = 0.26$, ryc. 5B), a także z czasem wykonania zadania kontrolnego ($r = -0.22, p = 0.34$, ryc. 5C). Znaleźliśmy natomiast istotną korelację z poziomem koncentracji określonym przez nauczyciela ($r = 0.47, p = 0.04$, ryc. 5A) oraz z nauczycielską oceną kompetencji matematycznych ($r = 0.46, p = 0.04$, ryc. 5E). Natomiast w przypadku oceny z matematyki z poprzedniego semestru zaobserwowaliśmy wyraźny trend ($r = 0.40, p = 0.07$, ryc. 5D).

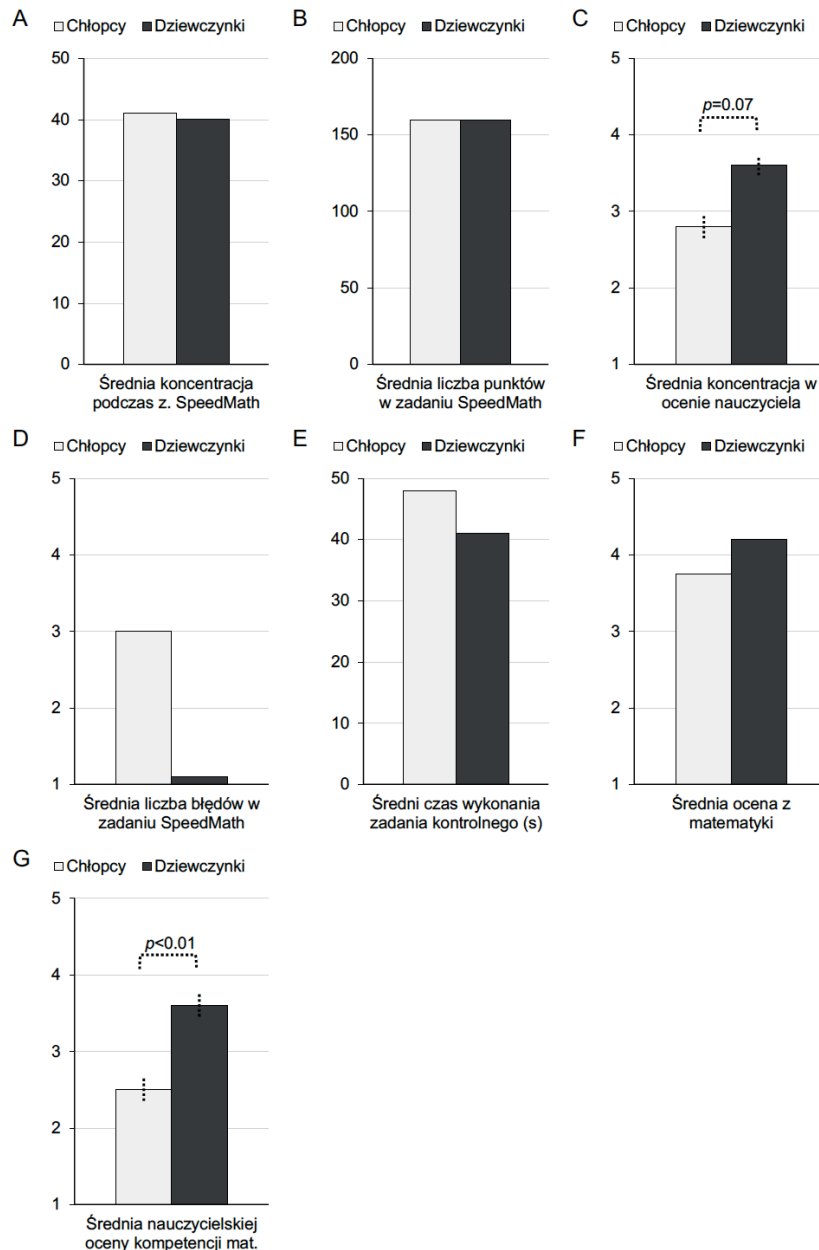
Widać zatem wyraźnie, że poziom kontrolowania koncentracji jest skorelowany z większą liczbą analizowanych parametrów niż średnia koncentracja, i zarówno te korelacje, jak i trendy, są w jego przypadku silniejsze. Najważniejsze jednak jest to, że wszystkie te zależności są pozytywne, a zatem że obliczony algorytmami neurofeedbacku poziom kontrolowania koncentracji podczas zadania matematycznego jest symetryczny względem innych cech ucznia. Ryc. 6 stanowi wizualizację sieci związków istniejących między średnią koncentracją i kontrolą koncentracji a innymi studiowanymi tu parametrami.



Ryc. 6. Sieć związków pomiędzy dwoma głównymi współczynnikami stosowanymi w neurofeedbacku a innymi parametrami związanymi z poznawczym funkcjonowaniem ucznia. (A) Wizualizacja sieci związków. Grubość połączeń pomiędzy węzłami sieci odzwierciedla siłę ich związku/symetryczności. (B) Mapa ciepłna ukazująca siłę i kierunek związków. KK-SM – kontrola koncentracji w zadaniu SpeedMath; ŚK-SM – średnia koncentracja podczas zadania SpeedMath; OM-5K – ocena z matematyki na koniec 5 klasy; UK-ON – umiejętność koncentracji w ocenie nauczyciela; CW-ZK – czas wykonania zadania kontrolnego; LB-SM – liczba błędów w zadaniu SpeedMath; KM-ON – kompetencje matematyczne w ocenie nauczyciela

2.3. Różnice w rozkładzie mierzonych parametrów ze względu na płeć badanych

Na ryc. 7 pokazano, że płeć nie różnicowała większości uzyskanych przez nas wyników. Dziewczynki i chłopcy przejawiali podobny poziom koncentracji podczas zadania SpeedMath, oscylujący wokół średniej grupowej wynoszącej 40.60 ($SD = 16.29$, $t = 0.13$, $p = 0.90$, ryc. 7A). Uzyskali także średnio taką samą liczbę



Ryc. 7. Różnice w rozkładzie mierzonych parametrów ze względu na płeć badanych. (A) Płeć nie różnicowała średniej koncentracji. (B) Płeć nie różnicowała kontroli koncentracji. (C) Płeć różnicowała koncentrację ocenianą przez wychowawcę. (D) Płeć nie różnicowała liczby popełnianych błędów. (E) Płeć nie różnicowała czasu wykonania zadania. (F) Płeć nie różnicowała ocen z matematyki. (G) Płeć różnicowała oceny kompetencji matematycznych formułowane przez wychowawcę. Słupki błędów ukazują błędy standardowe średniej

punktów w tym zadaniu (średnia grupowa = 159.40, $SD = 16.91$, $t < 0.001$, $p = 1.00$, ryc. 7B), a także popełniali podobną liczbę błędów (około 2, $SD = 2.61$, $t = 1.71$, $p = 0.10$, ryc. 7D). Czas potrzebny na wykonanie zadania kontrolnego również nie był dla nich różny i wynosił średnio 44.55 s ($SD = 25.80$ s, $t = 0.59$, $p = 0.56$, ryc. 7E). Płeć nie różnicowała ponadto ocen z matematyki – obie grupy uczniów średnio uzyskały z niej ocenę dobrą (średnia ocena = 3.98, $SD = 1.08$, $t = 0.93$, $p = 0.37$, ryc. 7F). Inaczej było jednak w przypadku parametrów bazujących na ocenie nauczyciela. Wychowawcy oceniali kompetencje matematyczne dziewczynek (średnia ocena = 3.60, $SD = 0.84$) istotnie wyżej (średnio o 1.10 punktu skali) w porównaniu do chłopców (średnia ocena = 2.50, $SD = 0.85$, $t = 2.91$, $p < 0.01$, ryc. 7G). W przypadku nauczycielskich ocen koncentracji występował analogiczny trend – koncentracja dziewczynek (średnia ocena = 3.60, $SD = 0.70$) była oceniana średnio o 0.80 punktu wyżej od koncentracji chłopców (średnia ocena = 2.80, $SD = 1.14$, $t = 1.90$, $p = 0.07$, ryc. 7C). Analizy te ukazują więc, że pomimo braku jakichkolwiek różnic w umiejętnościach matematycznych i tych związanych z koncentracją, nauczyciele różnicują opinie o uczniach ze względu na płeć, przeceniając kompetencje dziewczynki i nie doceniając chłopców. Stereotypowo przyjmuje się, że dziewczynki są lepsze od chłopców, jeśli chodzi o koncentrację, i że ogólnie są lepszymi uczniami (Gromkowska-Melosik, 2015). Niemniej, inny ze stereotypów zakłada, że chłopcy są lepsi z matematyki od dziewczynki (Kersey i in., 2019). Któryś z tych stereotypów wpłynął zapewne na oceny badanych przez nas wychowawców.

3. Dyskusja

W studium tym staraliśmy się sprawdzić, w jakim stopniu dwa podstawowe parametry wykorzystywane we wspomaganym neurofeedbackiem nauczaniu matematyki są skorelowane z innymi parametrami związanymi z poznawczym funkcjonowaniem ucznia czy parametrami analogicznymi, ale inaczej mierzonymi. Była to więc na przykład ocena z matematyki uzyskana na świadectwie ukończenia poprzedniej klasy, nauczycielska ocena kompetencji matematycznych ucznia i jego zdolności w zakresie koncentracji na zadaniu poznawczym, ale także liczba popełnianych przez ucznia błędów w zadaniu matematycznym i szybkość osiągnięcia wysokiej koncentracji w zadaniu niematematycznym. Okazało się, że bardzo często wykorzystywany w neurofeedbacku wskaźnik, oparty na średniej koncentracji podczas wykonywania danego (w naszym przypadku matematycznego) zadania, nie odzwierciedla innych wyróżników ucznia, zarówno tych związanych z kompetencjami matematycznymi, jak i tych, odnoszących się do umiejętności koncentracji. Inaczej było w przypadku drugiego z neurowskaźników, który opiera się na analizie biegłości w kontrolowaniu koncentracji podczas dokonywania obliczeń arytmetycznych. Ten parametr jest symetryczny względem większości analizowanych przez

nas zmiennych (i wszystkie te zależności nie są różnicowane przez płeć). Uzyskane wyniki pokazują więc z jednej strony, że pewne dane wytwarzane w procedurach biofeedbacku EEG mogą w rzeczywistości nie być czymś, co można by nazwać neurokorelatami cech behawioralnych. Z drugiej strony rezultaty te wskazują, że rzetelna analiza informacji generowanych przez neurofeedback może doprowadzić do wykrycia takich jego parametrów, które mogą być efektywnie wykorzystywane w edukacji. W konsekwencji opisywane tu efekty uzmysławiają, że neurofeedback może stanowić nową formę technologicznego wspomaganie procesu uczenia się matematyki, ale tylko wtedy, jeśli oprze się go na odpowiednio dobranych neuroparametrach. Te trzy wnioski omawiamy w kolejnych, odrębnych punktach dyskusji.

3.1. Neuroparametry i neuroartefakty generowane przez neurofeedback

Mimo tego, że w ostatnich latach przeprowadzono szereg badań nad neurofeedbackiem i jego zastosowaniem w terapii oraz edukacji, w niewielu przypadkach uzyskane dane były porównywane z funkcjonowaniem poznawczym osób badanych bądź z innymi cechami tychże osób. Raportowane korelacje lub ich brak dotyczyły zazwyczaj zestawienia wskaźników mierzonych biofeedbackiem EEG z innymi parametrami mierzonymi przez to samo urządzenie lub parametrami bezpośrednio dotyczącymi zadań czy aktywności, które były wykonywane przez uczestników w trakcie treningu (Chang i in., 2013; Nor i in., 2015; Kosmyna, Maes, 2019). Taki stan rzeczy jest bardzo niepokojący. Według Enriquez-Geppert i in. (2017) określenie poziomu skorelowania neuropomiarów i konkretnych funkcji poznawczych czy objawów, które miałyby być zmieniane poprzez neurofeedback, jest kluczowe dla zrozumienia potencjału tej metody. Krytyczne jest tu także monitorowanie skorelowania zmieniających się w wyniku treningu wartości neurowskaźnika ze zmianami parametrów trenowanej funkcji poznawczej. Co więcej, jedyne znane nam badanie nad tego typu zależnościami, przeprowadzone przez Hernandez i in. (2018), wykazało, że parametry generowane przez neurofeedback niekoniecznie muszą być skorelowane z realnymi cechami uczestników. Badacze ci uzyskali informacje na temat wpływu różnych czynników psychologicznych na poziom samoregulacji określonej klasy mikrostanów spontanicznej aktywności EEG (reprezentujących wszystkie jednocześnie aktywne źródła czynności elektrycznej mózgu, przedstawiane w formie topografii bądź map mózgu), w tym przypadku mikrostanu D (którego nieprawidłowości związane są z obecnością pozytywnych objawów psychotycznych u osób cierpiących na schizofrenię). Szczególnie interesowały ich cechy psychologiczne badanych, opisujące satysfakcję z życia, świadomość ciała, osobowość i poziom lęku. Zastosowana procedura wykazała, że jedna z cech określających satysfakcję z życia (*motivational incongruence*), którą można przedstawić jako pewną niezgodność

między tym, do czego człowiek świadomie dąży, a tym, co nieświadomie chciałby osiągnąć, jeśli chodzi o doświadczenia związane z dobrym samopoczuciem, jest skorelowana negatywnie ze średnim wzrostem mikrostanu D. Co ciekawe, mimo uwzględnienia wielu innych czynników psychologicznych, nie wykryto w tym eksperymencie innych istotnych korelacji. Nasze wyniki są więc ważnym głosem w empirycznie zaniedbanym obszarze analiz, ukazującym z jednej strony, że średnia koncentracja jest prawdopodobnie kolejnym tego typu neuroartefaktem, z drugiej natomiast, iż rejestracja umiejętności samoregulacji koncentracji stanowi obiektywny neuroparametr, przynajmniej w kontekście zastosowania neurofeedbacku w edukacji matematycznej.

3.2. Edukacyjna przydatność pomiarów kontroli koncentracji

Koncentracja, najogólniej rzecz biorąc, stanowi rdzeń procesu poznawczego, dzięki któremu jednostka może nabywać umiejętności w innych obszarach (Peng, Miller, 2016). Ludzki system uwagi jest bardzo skomplikowany, można go podzielić na sieci funkcjonalne, podfunkcje, a w końcu typy, wśród których wyróżniamy przedłużoną koncentrację (*sustained attention*). Termin ten nie do końca jest precyzyjny, w literaturze można spotkać różne sposoby definiowania go, niemniej w dużym uproszczeniu jest to umiejętność długotrwałego skupienia uwagi na bodźcach przez dłuższy czas, nie ulegając rozproszeniu przez czynniki wewnętrzne lub zewnętrzne (Fortenbaugh i in., 2017; Rivera i in., 2017; McDougal i in., 2020; Shannon i in., 2020). To ona jest odpowiedzialna za pomyślne wykonanie wielu zadań (Pereira i in., 2020) i jest czymś, co w naszym projekcie nazywamy kontrolą koncentracji. Liczne badania dowodzą, że jest silnie skorelowana z osiągnięciami szkolnymi (Steinmayr i in., 2010; Sawyer i in., 2015; Peng, Miller, 2016; Rabiner i in., 2016; por. Alavi i in., 2019; McDougal i in., 2020). Ta relacja dotyczy także osiągnięć w zakresie nauki matematyki (Alavi i in., 2019; Mundia, Metussin, 2019), co uzmysławia, że procesy rozwoju umiejętności koncentrowania się i kompetencji matematycznych przeplatają się, a także pozytywnie wpływają na siebie (Kim i in., 2018). Co więcej, diagnoza problemów z koncentracją (błądzenie myślami, rozproszenie, nieuwaga) jest swoistym zwiastunem przyszłych trudności w uczeniu się (Barnes i in., 2020) i jest skorelowana ze słabymi osiągnięciami w nauce (Polderman i in., 2010; Pham, 2016; Gray i in., 2017; Lundervold i in., 2017; Merrel i in., 2017; Pereira i in., 2020). Choć tło (etiologia) trudności w koncentracji jest bardzo zróżnicowane i może odnosić się zarówno do czynników genetycznych, jak i środowiskowych (Fortenbaugh i in., 2017; Shannon i in., 2020), związek między nimi a słabymi wynikami w nauce jest bardzo dobrze udokumentowany empirycznie. Potwierdzono go zarówno w badaniach z udziałem uczniów o specjalnych potrzebach edukacyjnych, na przykład z zespołem nadpobudliwości psychoruchowej z deficytem uwagi (ADHD) (Lundervold i in., 2017; Owens,

Jackson, 2017), jak i tych rozwijających się typowo (Alavi i in., 2019). Uczniowską zdolność do kontroli koncentracji można jednak stymulować (poprawić) zarówno poprzez zaciekawienie przedmiotem nauki czy manipulowaniem szkolnym – fizycznym i niefizycznym – środowiskiem (Li, Yang, 2016; Erwiza i in., 2019), ale także poprzez różnorakie interwencje. Eksperymenty wykazały, że trening koncentracji dość szybko przynosi efekty, zarówno w postaci poprawy uwagi, jak i lepszych wyników w nauce (Sawyer i in., 2015; Fortenbaugh i in., 2017; McDougal i in., 2020), a także wzrostu wydajności innych umiejętności poznawczych (Peng, Miller, 2016). Nasze wyniki wpisują się w tę debatę, ukazując silne skorelowanie mierzonej poprzez MindWave kontroli koncentracji z innymi cechami funkcjonowania ucznia. Pokazują także, że neurofeedback może być realnym treningiem kontroli koncentracji, jako że pomiary dokonywane przez urządzenia typu MindWave wydają się być w tym zakresie wiarygodne. Konkludując, nasz eksperyment sugeruje, że kontrola koncentracji stanowi neuroparametr edukacyjnie przydatny.

3.3. Technologiczne wspomaganie edukacji matematycznej neurofeedbackiem

Panuje raczej ogólna zgoda co do tego, że technologie informacyjno-komunikacyjne (ICT) mogą być skutecznym narzędziem wspomagającym uczenie się matematyki (Clements, Sarama, 2003; Demir, Basol, 2014; Crompton, Traxler, 2015; Drigas i in., 2015; Larkin, Calder, 2016; Chauhan, 2017; Young, 2017; Griffith i in., 2020; Verbruggen i in., 2020). Z jednej strony liczne badania wykazały, że ICT sprawiają, iż treści matematyczne – często trudne do nauczania ze względu na swą abstrakcyjność i złożoność – zaczynają być bliższe codzienności i poznawczo atrakcyjniejsze (Klibanoff i in., 2006; Borba i in., 2017; Fraillon i in., 2019; MacDonald, Murphy, 2019; Hillmayr i in., 2020; Verbruggen i in., 2020). Z drugiej natomiast wiele studiów empirycznych pokazało, że ICT stymulują mechanizmy sprzyjające rozwojowi matematycznemu (Duncan i in., 2007; Li, Ma, 2010; Cheung, Slavin, 2013; Piasta i in., 2014; Young, 2017) i dają szansę na holistyczne kształtowanie matematycznych kompetencji (Klichowski, Przybyła, 2017; Clements, Sarama, 2018; Przybyła, Klichowski, 2018b; Przybyła i in., 2020), a w konsekwencji podnoszą ogólne wyniki uczenia się matematyki, zwiększając płynności i tempo wykonywanych działań arytmetycznych i zmniejszając liczbę popełnianych błędów (Kurvinen i in., 2020).

Jednakże w raportach naukowych sygnalizowane są też pewne kontrowersje w tym kontekście. Krytycy podkreślają, że wiele z badań nad technologicznym wspomaganie edukacji matematycznej ma niedociągnięcia teoretyczne i metodologiczne, bazuje na nieaktualnych danych czy koncentruje się na wąskiej grupie uczniów (Verbruggen i in., 2020). Pojawiają się także opinie, że stosowanie ICT na zajęciach matematycznych nie zmienia ich efektywności (Vanbecelaere i in.,

2020), a nawet, iż może ją obniżyć (Oates, 2011; Hardman, 2015; 2019; Lameras, Moumoutzis, 2015; Fraillon i in., 2019; Drijvers, 2020). Uzyskane przez nas wyniki wspierają zdecydowanie nurt ukazujący potencjał ICT w edukacji matematycznej. Nawet tak prosta gra komputerowa jak SpeedMath i tak nieskomplikowane urządzenie jak jednoelektrodowe mobilne EEG, mogą stanowić świetny zestaw wspierający nauczyciela w procesie kształtowania kompetencji matematycznych ucznia. Potwierdzają to także ostatnie badania Es-Sajjade'a i Paasa (2020), w których wykazano, że granie w całkiem zwyczajne interaktywne gry matematyczne silnie podnosi osiągnięcia matematyczne uczniów. Wyniki studiów Kurvinena i in. (2020) sugerują, że taki pozytywny efekt można uzyskać nawet przy sporadycznym używaniu ICT w edukacji matematycznej, np. raz w tygodniu. Nie potrzeba zatem skomplikowanej aparatury i radykalnych zmian w programie kształcenia, by z sukcesem wspomagać technologicznie edukację matematyczną.

Podsumowanie

Bez wątplenia nasze badania mają pewne ograniczenia, zarówno w zakresie doboru próby i jej liczności, jak i zastosowanej procedury. Jednakże ukazują one wyraźnie, że przy odpowiednim zagłębieniu się w specyfikę pomiarów neurofeedbacku i zrozumieniu ich subtelnosci, trening kontroli umysłu może być ważnym elementem edukacji matematycznej i stanowić pewną innowację w zakresie technologicznego wspomaganie procesu uczenia się matematyki. W przyszłych badaniach należy podjąć trud eksperymentalnego przetestowania różnych wariantów takiego treningu, a także dynamiki skorelowania zmieniających się w jego wyniku parametrów. Rekomendujemy, by biologiczną informacją zwrotną był w takim treningu poziom kontroli koncentracji.

Wkład autorów

Koncepcja badań została opracowana przez MK. Dane były zbierane przez TP, AK i MD, opracowane przez TP i MK, przeanalizowane przez MK i zinterpretowane przez MK, AK i WR. Wizualizację sieci przeprowadził MK. Strukturę rozdziału opracował MK. Wszyscy autorzy uczestniczyli w jego pisaniu i zebraniu źródeł. Ryciny zostały przygotowane przez MK, TP i AK.

Podziękowania

Składamy podziękowania Adamowi Majerowi oraz jego wychowawczyni, Pani Alicji Przybyłek, za zainspirowanie nas do podjęcia opisanych w rozdziale badań. Były one w całości realizowane w ramach grantu European Cooperation in Science and Technology: *European Network on Brain Malformations (Neuro-MIG)* (CA

COST Action CA16118), którego MK jest naukowym koordynatorem, a TP wykonawcą. COST jest częścią EU Framework Programme for Research and Innovation Horizon 2020. Sprzęt EEG użyty w eksperymencie został zakupiony ze środków Stypendium dla Wybitnych Młodych Naukowców ufundowanego przez Ministerstwo Nauki i Szkolnictwa Wyższego (stypendium nr 0049/E-336/STYP/11/2016) i przyznanego MK.

BIBLIOGRAFIA

- Alavi, M., Seng, J.H., Mustaffa, M.S., Ninggal, M.T., Amini, M., Latif, A.A. (2019). Attention, impulsiveness, and gender in academic achievement among typically developing children. *Perceptual and Motor Skills*, 126 (1), 5–24.
- Barnes, M.A., Clemens, N.H., Fall, A.M., Roberts, G., Klein, A., Starkey, P., Flynn, K. (2020). Cognitive predictors of difficulties in math and reading in pre-kindergarten children at high risk for learning disabilities. *Journal of Educational Psychology*, 112 (4), 685–700.
- Bindhu, V. (2020). An enhanced safety system for auto mode e-vehicles through Mind Wave feedback. *Journal of Information Technology and Digital World*, 2 (3), 144–150.
- Borba, M.C., Askar, P., Engelbrecht, J., Gadanidis, G., Llinares, S., Aguilar, M.S. (2017). *Digital technology in mathematics education: Research over the last decade*. [w:] G. Kaiser (red.), *Proceedings of the 13th International Congress on Mathematical Education*. Cham: Springer, 221–233.
- Chang, K.M., Nelson, J., Pant, U., Mostow, J. (2013). Toward exploiting EEG input in a reading tutor. *International Journal of Artificial Intelligence in Education*, 22, 19–38.
- Chauhan, S. (2017). A meta-analysis of the impact of technology on learning effectiveness of elementary students. *Computers & Education*, 105, 14–30.
- Cheng, C.H., Li, S., Kadry, S. (2018). Mind-Wave controlled robot: An Arduino Robot simulating the wheelchair for paralyzed patients. *International Journal of Robotics and Control*, 1 (1), 6–19.
- Cheung, A.C., Slavin, R.E. (2013). The effectiveness of educational technology applications for enhancing mathematics achievement in K-12 classrooms: A meta-analysis. *Educational Research Review*, 9, 88–113.
- Chiba, T., Kanazawa, T., Koizumi, A., Ide, K., Taschereau-Dumouchel, V., Boku, S., Yoneda, H. (2019). Current status of neurofeedback for post-traumatic stress disorder: A systematic review and the possibility of decoded neurofeedback. *Frontiers in Human Neuroscience*, 13, 233.
- Clements, D.H., Sarama, J. (2003). Young children and technology: what does the research say. *Young Children*, 58 (6), 34–40.
- Clements, D.H., Sarama, J. (2018). Myths of early math. *Education Sciences*, 8 (2):71.
- Crompton, H., Traxler, J. (red.). (2015). *Mobile learning and mathematics: foundations, design, and case studies*. New York: Routledge.
- Demir, S., Basol, G. (2014). Effectiveness of computer-assisted mathematics education (CAME) over academic achievement: A meta-analysis study. *Educational Sciences: Theory and Practice*, 14 (5), 2026–2035.
- Demos, J.N. (2019). *Getting started with EEG neurofeedback*. New York: W.W. Norton & Company.
- Drigas, A., Kokkalia, G., Lytras, M.D. (2015). ICT and collaborative co-learning in preschool children who face memory difficulties. *Computers in Human Behavior*, 51, 645–651.
- Drijvers, P. (2020). *Digital tools in Dutch mathematics education: a dialectic relationship*. [w:] M. Van den Heuvel-Panhuizen (red.), *National Reflections on the Netherlands Didactics of Mathematics*. Cham: Springer, 177–195.

- Duncan, G.J., Dowsett, C.J., Claessens, A., Magnuson, K., Huston, A.C., Klebanov, P., Sexton, H. (2007). School readiness and later achievement. *Developmental Psychology*, 43 (6), 1428–1446.
- Enriquez-Geppert, S., Huster, R.J., Herrmann, C.S. (2017). EEG-neurofeedback as a tool to modulate cognition and behavior: a review tutorial. *Frontiers in Human Neuroscience*, 11, 51.
- Erickson, L.C., Thiessen, E.D., Godwin, K.E., Dickerson, J.P., Fisher, A.V. (2015). Endogenously and exogenously driven selective sustained attention: Contributions to learning in kindergarten children. *Journal of Experimental Child Psychology*, 138, 126–134.
- Erwiza, E., Kartiko, S., Gimin, G. (2019). Factors affecting the concentration of learning and critical thinking on student learning achievement in economic subject. *Journal of Educational Sciences*, 3 (2), 205–215.
- Es-Sajjade, A., Paas, F. (2020). Educational theories and computer game design: lessons from an experiment in elementary mathematics education. *Educational Technology Research and Development*, 68, 2685–2703.
- Fortenbaugh, F.C., DeGutis, J., Esterman, M. (2017). Recent theoretical, neural, and clinical advances in sustained attention research. *Annals of the New York Academy of Sciences*, 1396 (1), 70–91.
- Fraillon, J., Ainley, J., Schulz, W., Duckworth, D., Friedman, T. (2019). *IEA international computer and information literacy study 2018 assessment framework*. Cham: Springer.
- Goodman, M.S., Castro, N., Sloan, M., Sharma, R., Widdowson, M., Herrera, E., Pineda, J.A. (2018). A neurovisceral approach to autism: Targeting self-regulation and core symptoms using neurofeedback and biofeedback. *NeuroRegulation*, 5 (1), 9–29.
- Górska, M., Olszewski, M. (2015). Interfejs mózg–komputer w zadaniu sterowania robotem mobilnym. *Pomiary Automatyka Robotyka*, 19 (3), 15–24.
- Gray, S.A., Dueck, K., Rogers, M., Tannock, R. (2017). Qualitative review synthesis: the relationship between inattention and academic achievement. *Educational Research*, 59 (1), 17–35.
- Griffith, S.F., Hagan, M.B., Heymann, P., Heflin, B.H., Bagner, D.M. (2020). Apps as learning tools: a systematic review. *Pediatrics*, 145 (1): e20191579.
- Gromkowska-Melosik, A. (2015). Women’s education and professional success. Paradoxes of access and exclusion. *Journal of Gender and Power*, 2, 9–21.
- Hardman, J. (2015). Pedagogical variation with computers in mathematics classrooms: A cultural historical activity theory analysis. *Psychology in Society*, 48, 47–76.
- Hardman, J. (2019). Towards a pedagogical model of teaching with ICTs for mathematics attainment in primary school: A review of studies 2008–2018. *Heliyon*, 5 (5): e01726.
- Hashemian, P., Hashemian, P. (2015). Effectiveness of neuro-feedback on mathematics disorder. *African Journal of Psychiatry*, 18 (2), 1000243.
- Hernandez, L.D., Rieger, K., Koenig, T. (2018). Low motivational incongruence predicts successful EEG resting-state neurofeedback performance in healthy adults. *Neuroscience*, 378, 146–154.
- Hillmayr, D., Ziernwald, L., Reinhold, F., Hofer, S.I., Reiss, K.M. (2020). The potential of digital tools to enhance mathematics and science learning in secondary schools: A context-specific meta-analysis. *Computers & Education*, 153: 103897.
- Hinrichs, H., Scholz, M., Baum, A.K., Kam, J.W., Knight, R.T., Heinze, H.J. (2020). Comparison between a wireless dry electrode EEG system with a conventional wired wet electrode EEG system for clinical applications. *Scientific Reports*, 10, 5218.
- Huang, H.W., King, J.T., Lee, C.L. (2020). The new science of learning: Using the power and potential of the brain to inform digital learning. *Educational Technology and Society*, 23 (4), 1–13.
- Kam, J.W., Griffin, S., Shen, A., Patel, S., Hinrichs, H., Heinze, H.J., Knight, R.T. (2019). Systematic comparison between a wireless EEG system with dry electrodes and a wired EEG system with wet electrodes. *NeuroImage*, 184, 119–129.
- Kersey, A.J., Csumitta, K.D., Cantlon, J.F. (2019). Gender similarities in the brain during mathematics development. *npj Science of Learning*, 4: 19.

- Kim, H., Duran, C.A., Cameron, C.E., Grissmer, D. (2018). Developmental relations among motor and cognitive processes and mathematics skills. *Child Development*, 89 (2), 476–494.
- Kirk, H.W. (red.). (2015). *Restoring the brain: Neurofeedback as an integrative approach to health*. New York: Routledge.
- Klibanoff, R.S., Levine, S.C., Huttenlocher, J., Vasilyeva, M., Hedges, L.V. (2006). Preschool children's mathematical knowledge: The effect of teacher "math talk". *Developmental Psychology*, 42 (1), 59–69.
- Klichowski, M. (2017). *Learning in CyberParks. A theoretical and empirical study*. Poznań: Wydawnictwo Naukowe UAM.
- Klichowski, M., Przybyła, T. (2017). *Does cyberspace increase young children's numerical performance? A brief overview from the perspective of cognitive neuroscience*. [w:] H. Krauze-Sikorska, M. Klichowski (red.), Świat małego dziecka. *Przestrzeń instytucji, cyberprzestrzeń i inne przestrzenie dzieciństwa*. Poznań: Wydawnictwo Naukowe UAM, 425–444.
- Klichowski, M., Nowik, A., Kroliczak, G., Lewis, J.W. (2020). Functional lateralization of tool-sound and action-word processing in a bilingual brain. *Health Psychology Report*, 8 (1), 10–30.
- Kosmyna, N., Maes, P. (2019). AttentivU: an EEG-based closed-loop biofeedback system for real-time monitoring and improvement of engagement for personalized learning. *Sensors*, 19 (23): 5200.
- Kounte, M.R., Tripathy, P.K., Pramod, P., Bajpai, H. (2020). Implementation of brain machine interface using Mind wave sensor. *Procedia Computer Science*, 171, 244–252.
- Kurvinen, E., Kaila, E., Laakso, M.J., Salakoski, T. (2020). Long term effects on technology enhanced learning: The use of weekly digital lessons in mathematics. *Informatics in Education*, 19 (1), 51–75.
- Lameras, P., Moumoutzis, N. (2015). *Towards the gamification of inquiry-based flipped teaching of mathematics a conceptual analysis and framework*. [w:] 2015 International Conference on Interactive Mobile Communication Technologies and Learning (IMCL). Thessaloniki: IEEE, 343–347.
- Larkin, K., Calder, N. (2016). Mathematics education and mobile technologies. *Mathematics Education Research Journal*, 28, 1–7.
- LaRocco, J., Le, M.D., Paeng, D.G. (2020). A systematic review of available low-cost EEG headsets used for drowsiness detection. *Frontiers in Neuroinformatics*, 14, 553352.
- Li, Q., Ma, X. (2010). A meta-analysis of the effects of computer technology on school students' mathematics learning. *Educational Psychology Review*, 22, 215–243.
- Li, X., Yang, X. (2016). Effects of learning styles and interest on concentration and achievement of students in mobile learning. *Journal of Educational Computing Research*, 54 (7), 922–945.
- Lundervold, A.J., Meza, J.I., Hysing, M., Hinshaw, S.P. (2017). Parent rated symptoms of inattention in childhood predict high school academic achievement across two culturally and diagnostically diverse samples. *Frontiers in Psychology*, 8: 1436.
- MacDonald, A., Murphy, S. (2019). Mathematics education for children under four years of age: A systematic review of the literature. *Early Years*, 1–18.
- Marzbani, H., Marateb, H.R., Mansourian, M. (2016). Neurofeedback: A comprehensive review on system design, methodology and clinical applications. *Basic and Clinical Neuroscience*, 7 (2), 143–158.
- McDougal, E., Riby, D.M., Hanley, M. (2020). Profiles of academic achievement and attention in children with and without Autism Spectrum Disorder. *Research in Developmental Disabilities*, 106: 103749.
- Merrell, C., Sayal, K., Tymms, P., Kasim, A. (2017). A longitudinal study of the association between inattention, hyperactivity and impulsivity and children's academic attainment at age 11. *Learning and Individual Differences*, 53, 156–161.
- Molina-Cantero, A.J., Guerrero-Cubero, J., Gómez-González, I.M., Merino-Monge, M., Silva-Silva, J.I. (2017). Characterizing computer access using a one-channel EEG wireless sensor. *Sensors*, 17 (7): 1525.
- Mundia, L., Metussin, H. (2019). Exploring factors that improve mathematics achievement in Brunei. *Studies in Educational Evaluation*, 60, 214–222.

- Ni, D., Wang, S., Liu, G. (2020). The EEG-based attention analysis in multimedia m-learning. *Computational and Mathematical Methods in Medicine*, 2020: 4837291.
- Nor, N.M., Bar, A.W., Salleh, S.H.S. (2015). Correlation of Student's precursor emotion towards learning science interest using EEG. *Telkomnika*, 13 (4), 1162–1169.
- Oates, G. (2011). Sustaining integrated technology in undergraduate mathematics. *International Journal of Mathematical Education in Science and Technology*, 42 (6), 709–721.
- Owens, J., Jackson, H. (2017). Attention-deficit/hyperactivity disorder severity, diagnosis, and later academic achievement in a national sample. *Social Science Research*, 61, 251–265.
- Peake, J.M., Kerr, G., Sullivan, J.P. (2018). A critical review of consumer wearables, mobile applications, and equipment for providing biofeedback, monitoring stress, and sleep in physically active populations. *Frontiers in Physiology*, 9, 743.
- Peng, P., Miller, A.C. (2016). Does attention training work? A selective meta-analysis to explore the effects of attention training and moderators. *Learning and Individual Differences*, 45, 77–87.
- Pereira, E.J., Gurguryan, L., Ristic, J. (2020). Trait-Level variability in attention modulates mind wandering and academic achievement. *Frontiers in Psychology*, 11: 909.
- Pham, A.V. (2016). Differentiating behavioral ratings of inattention, impulsivity, and hyperactivity in children: effects on reading achievement. *Journal of Attention Disorders*, 20 (8), 674–683.
- Piasta, S.B., Pelatti, C.Y., Miller, H.L. (2014). Mathematics and science learning opportunities in preschool classrooms. *Early Education and Development*, 25 (4), 445–468.
- Polderman, T.J., Boomsma, D.I., Bartels, M., Verhulst, F.C., Huizink, A.C. (2010). A systematic review of prospective studies on attention problems and academic achievement. *Acta Psychiatrica Scandinavica*, 122 (4), 271–284.
- Przybyła, T., Bronikowski, M., Bzdęga, B., Cichy, I., Hofman, J., Hrybiuk, O., Klichowski, M. (2020). *Dziecięca matematyka*. [w:] H. Krauze-Sikorska, M. Klichowski (red.), *Pedagogika dziecka*, Poznań: Wydawnictwo Naukowe UAM.
- Przybyła, T., Klichowski, M. (2018a). Codzienne operacje arytmetyczne a problem kosztów podwójnego zadania: raport z eksperymentu behawioralnego kontrolowanego elektroencefalografem. *Studia Edukacyjne*, 49, 145–157.
- Przybyła, T., Klichowski, M. (2018b). „Cyfrowe liczby”: Przykłady narzędzi ICT służących kształtowaniu kompetencji matematycznych ucznia poprzez stymulację praktyki. [w:] *Psychoedukacyjne problemy młodzieży, czyli jak być świadomym wychowawcą*. Poznań: Kuratorium Oświaty w Poznaniu, 56–64.
- Qin, L.Y., Nasir, N.M., Huq, M.S., Ibrahim, B.S.K.K., Narudin, S.K., Alias, N.A., i Ab Ghani, M.A. (2020). Smart home control for disabled using brain computer interface. *International Journal of Integrated Engineering*, 12 (4), 74–82.
- Rabiner, D.L., Godwin, J., Dodge, K.A. (2016). Predicting academic achievement and attainment: The contribution of early academic skills, attention difficulties, and social competence. *School Psychology Review*, 45 (2), 250–267.
- Ratti, E., Waninger, S., Berka, C., Ruffini, G., Verma, A. (2017). Comparison of medical and consumer wireless EEG systems for use in clinical trials. *Frontiers in Human Neuroscience*, 11, 398.
- Reddy, J.K., Sneha, C.S. (2019). EEG neurofeedback brain training for epilepsy to reduce seizures. *International Journal of Child Development and Mental Health*, 7 (1), 28–33.
- Rivera, D., Salinas, C., Ramos-Usuga, D., Delgado-Mejía, I.D., Vasallo Key, Y., Hernández Agurcia, G.P., Romero-García, I. (2017). Concentration endurance test (d2): Normative data for Spanish-speaking pediatric population. *NeuroRehabilitation*, 41 (3), 661–671.
- Sadudeemeechaitaweechoke, S., Boonyahotra, V., Sittiprapaporn, P. (2017). *Electroencephalographic study of real-time arithmetic task recognition*. [w:] *14th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)*, Phuket: IEEE, 42–45.

- Sałabun, W. (2014). Processing and spectral analysis of the raw EEG signal from the MindWave. *Przegląd Elektrotechniczny*, 90 (2), 169–173.
- Sawangjai, P., Hompoonsup, S., Leelaarporn, P., Kongwudhikunakorn, S., Wilaiprasitporn, T. (2019). Consumer grade EEG measuring sensors as research tools: A review. *IEEE Sensors Journal*, 20 (8), 3996–4024.
- Sawyer, A.C.P., Chittleborough, C.R., Mittinty, M.N., Miller-Lewis, L.R., Sawyer, M.G., Sullivan, T., Lynch, J.W. (2015). Are trajectories of self-regulation abilities from ages 2–3 to 6–7 associated with academic achievement in the early school years? *Child: Care, Health and Development*, 41 (5), 744–754.
- Shannon, K.A., Scerif, G., Raver, C.C. (2020). Using a multidimensional model of attention to predict low-income preschoolers' early academic skills across time. *Developmental Science*, 00: e13025.
- Sittiprapaporn, P., Chang, S.-C. (2019). Electroencephalographic study of real-time arithmetic task recognition in learning disabilities children. *Asian Journal of Medical Sciences*, 10 (1), 43–46.
- Steinmayr, R., Ziegler, M., Träuble, B. (2010). Do intelligence and sustained attention interact in predicting academic achievement? *Learning and Individual Differences*, 20, 14–18.
- Tabakcioğlu, M., Çizmeci, H., i Ayberkin, D. (2016). Neurosky EEG biosensor using in education. *International Journal of Applied Mathematics Electronics and Computers*, 4, 76–78.
- Vanbecelaere, S., Van den Berghe, K., Cornillie, F., Sasanguie, D., Reynvoet, B., Depaepe, F. (2020). The effects of two digital educational games on cognitive and non-cognitive math and reading outcomes. *Computers & Education*, 143: 103680.
- Verbruggen, S., Depaepe, F., Torbeyns, J. (2020). Effectiveness of educational technology in early mathematics education: A systematic literature review. *International Journal of Child-Computer Interaction*, 27: 100220.
- Vuckovic, A., Altaleb, M.K.H., Fraser, M., McGeady, C., Purcell, M. (2019). EEG correlates of self-managed neurofeedback treatment of central neuropathic pain in chronic spinal cord injury. *Frontiers in Neuroscience*, 13, 762.
- Xu, J., Zhong, B. (2018). Review on portable EEG technology in educational research. *Computers in Human Behavior*, 81, 340–349.
- Young, J. (2017). Technology-enhanced mathematics instruction: A second-order meta-analysis of 30 years of research. *Educational Research Review*, 22, 19–33.
- Zerafa, R., Camilleri, T., Falzon, O., Camilleri, K.P. (2018). A comparison of a broad range of EEG acquisition devices – is there any difference for SSVEP BCIs? *Brain-Computer Interfaces*, 5 (4), 121–131.