

Anna Aleksandra Kaszyńska*

ORCID: 0000-0001-6374-3272

Uniwersytet Humanistyczno-Społeczny SWPS

CHOROBA ALZHEIMERA JAKO PRZYKŁAD DESYNCHRONIZACJI FUNKCJONOWANIA I ZBIÓR NEUROKOGNITYWNYCH WZORCÓW STANOWIĄCYCH POTENCJALNE ŹRÓDŁO ZASOBÓW DLA ROZWOJU SZTUCZNEJ INTELIGENCJI

Artykuł omawia możliwości potencjalnego rozwoju sztucznej inteligencji w wyniku wyszukiwania (za pomocą uczenia maszynowego, uczenia głębokiego oraz innych matematycznych obliczeń) stałych wzorców i prawidłowości, które umożliwiają usprawnienie i udoskonalenie zaawansowanych analiz w dziedzinie uczenia sztucznych sieci neuronowych. Narracja prowadzona jest przez pryzmat neurokognitywistycznego spojrzenia na chorobę Alzheimera jak na zbiór neurokognitywnych wzorców stanowiących potencjalne źródło zasobów dla rozwoju sztucznej inteligencji. Związane jest to ściśle z encefalografią, zarówno służącą do detekcji patologicznych zmian demencyjnych, jak i samej analizy aktywności mózgu wykazującej istnienie powtarzających się prawidłowości. Te powtarzające się wzorce, tak jak w przypadku astrofizycznych lagrandreowskich analiz umożliwiających mapowanie galaktyki, zdają się wykazywać potencjał do rozwoju sztucznej inteligencji. Ujmując chorobę Alzheimera jako desynchronizację ogólnego funkcjonowania i spoglądając wówczas na zmiany neurodegeneracyjne jako na potencjalne zasoby, które w wyniku matematycznych i algebraicznych przekształceń posłużyć mogą za płodne podłoże rozwoju sztucznej inteligencji.

Słowa kluczowe: EEG, sztuczna inteligencja, choroba Alzheimera, uczenie głębokie, fale mózgowo

SYNTEZA INDUKCJI I DEDUKCJI – SZTUCZNA INTELIGENCJA VS. CHOROBA ALZHEIMERA

Istnieją liczne opracowania, koncepcje teoretyczne czy obserwacje z życia codziennego dotyczące psychospołecznego stanu funkcjonowania – jego skuteczności, płynności, wpływu na inne dziedziny, w tym na stan psychiczny jednostki czy kształty i barwy relacji międzyludzkich.

* Centrum Badań Neuropoznawczych SWPS, Uniwersytet Humanistyczno-Społeczny SWPS, ul. Chodakowska 19/31, 03-815 Warszawa, Polska; e-mail: akaszynska@swps.edu.pl

W dzisiejszych czasach związek między sztuczną inteligencją a życiem codziennym wydaje się coraz mocniejszy. Można zaobserwować również jego zalety i wady. Niemniej jego wpływ na funkcjonowanie większości aspektów życia wydaje się niezaprzeczalny. A także (nie biorąc pod uwagę charakteru tego oddziaływania) można go powiązać ze skutecznością i dokładnością przekazu informacji.

Podkreślenie związku między sztuczną inteligencją a życiem codziennym, gdyż oba wydają się zdeterminowane zjawiskiem komunikacji, rozumianym również jako przekaz informacji, może korespondować z interpretacją przekazu w kategoriach wymiany niektórych zbiorów symbolicznych (np. znaczki pocztowe).

Zgodnie ze znaczeniem pojęć „intra” i „inter” w omówieniu zjawiska wymiany sztuczną inteligencję można uznać za zbiór sieci oddziałujących z aspektami życia: zaczynając od cyberbezpieczeństwa, przechodząc przez koncepcje programowania obiektowego, a kończąc na polu biomedycznym rozpatrywanym zarówno z punktu widzenia funkcjonowania organizmu, jak i neuroinformatyki biomedycznej.

Artykuł poglądowy poświęcony jest tematyce potencjalnego rozwoju sztucznej inteligencji opartego na wzorcach pozyskiwanych np. z matematycznych obliczeń i operacji dokonywanych na dynamicznych danych w wyniku analiz częstości, które uzyskane mogą zostać z weryfikacji aktywności mózgu narzędziami EEG oraz na wzorcach wyłonionych na drodze analizy zmian funkcji fizjologicznych w przypadku neurodegeneracji.

A wszystkie hipotezy wyłaniające się z analiz interdyscyplinarnych badań będą oscylować wokół fenomenu konstruktów sieci (neuronalnych oraz neuronowych) i powiązanego z nimi transferu danych – postrzeganych również jako dane śladów pamięciowych.

Całość wywodu, oscylującego wokół konceptu sieci, interakcji w ich obrębie oraz determinowania przez nie jakości przekazywania wszelkich informacji, rozpocznie się od zobrazowania siły wpływu, jaki posiadają wzorce uzyskane z matematyczno-logicznych obliczeń, na możliwość „zautomatyzowanego” i metaforycznie ujmując, autogenerującego się częściowo nadzorowanego rozwoju „inteligentnych osobników nowego gatunku”.

Poprzez swoiste nawiązanie do „generatywnych” prawidłowości, powstałych w wyniku Wielkiego Wybuchu, nastąpi zwrot ku zjawisku AD, gdyż obejmuje ona analogicznie globalność (aczkolwiek w tym przypadku globalność sprowadzona zostaje do „mikrokosmosu”, jakim będzie wnętrze organizmu ludzkiego).

Następnie „mikrokosmos” organizmu ludzkiego można rozważyć jako „makrokosmos” w stosunku do sieci, jakie kreowane są przez fale mózgowe i ich interakcje. Właściwości, które ulokowane są w oscylacjach neuronalnych, determinując funkcjonowanie, mogą wykazywać przy okazji prawidłowość bycia „elementem”, który okaże się zarazem przyczyną, jak i efektem ewentualnych zmian degeneracyjnych.

Odwolując się do prawidłowości matematycznych przekształceń (jak np. transpozycji czy odwrotności), można zauważyć potencjał rozwoju drzemiący w analizach częstości fal mózgowych, które będą obarczone prawidłowościami zmian neurodegeneracyjnych.

Na potencjalny rozwój sztucznej inteligencji spojrzę przez pryzmat interdyscyplinarnego zbioru prawidłowości, który może zostać zobrazowany metaforycznym nawiązaniem do zjawiska wstęgi Möbiusa, w przypadku której ta sama płaszczyzna okazuje się jednocześnie polem wewnętrznym, jak i zewnętrznym.

W obszarze artykułu wspomnianymi płaszczyznami będzie przyczyna i skutek lokujące się np. w parametryczności macierzy powstałej z analiz częstości fal mózgowych. A powstałe parametry faz, amplitudy czy częstotliwości, pozostające ze sobą w dynamicznej interakcji będą zarówno podlegać zmianom degeneracyjnym, jak i same będą determinować rozwój tych zmian¹.

Mimo wielu zasadniczych różnic pod względem funkcjonowania, zdolności obliczeniowych i sposobu dokonywania transferu danych sieci neuronowe opierają się na strukturze neurobiologicznej i funkcjonowaniu układu nerwowego (co przejawia się w połączeniach dendrytów, aksonów i synaps) (Aggrawal, 2018).

Wychodząc od tej biologicznej inspiracji oraz obserwacji, które wyłaniają się ze współczesnych badań, dotyczących zarówno choroby Alzheimera (AD), jak i powiązań między inteligencją oraz kreatywnością a wyładowaniami elektrycznymi pojedynczych neuronów (nawiązują również do jakości procesów powiązanych z uwagą (Jha et al., 2017, Tamura et al., 2017; Vaswani et al., 2017), artykuł skupiać się będzie na potencjalnym połączeniu (głównie) neurokognitywnych wzorców AD z rozwojem sztucznej inteligencji.

Dodatkowo nawiązywać będzie do architektury i idei Boltzmann Machine oraz Restricted Boltzmann Machine (RBM), gdyż zestawienie architektury i idei Boltzmann Machine z prawidłowościami układu endokannabinoidowego (który podobnie jak RBM wspiera, determinuje i opiera się na prawach termodynamiki, traktujących o zachowaniu homeodynamicznego środowiska zamkniętego układu energetycznego) wydaje się wpisywać w koncepcję interdyscyplinarnego połączenia obszaru sztucznej inteligencji i biologicznego obszaru organizmu.

Ponadto artykuł odwoływać się będzie do interdyscyplinarnych badań łączących owocne wykorzystanie architektury uczenia głębokiego wraz ze wzorcami dużych zbiorów danych – wzorców, które uzyskano w wyniku zastosowania matematycznych i analitycznych obliczeń.

Równoległą ideą i osią spajającą artykuł, a zarazem myślą i prawidłowością wykazującą istotne znaczenie w każdej z omawianych dziedzin jest fenomen komunikacji.

Nie tylko na polu społecznym zapewnia on jakość nawiązywania więzi, ekspresji czy przekazywania informacji, ale również w dziedzinach biologicznych czy bioneurowinformatycznych komunikacja (co prawda, postrzegana bardziej w kontekście jakości transferu danych czy koordynacji współpracy układów fizjologicznych, czemu towarzyszyć będzie prosperowanie organizmu) znajduje znaczące odzwierciedlenie.

NEURODEGENERACYJNE ZABURZENIA JAKO ZABURZENIA KOMUNIKACJI UKŁADÓW ORGANICZNYCH

UKŁAD ENDOKANNABINOIDOWY – SYNCHRONIZACJA KOMUNIKACJI USTROJOWEJ

Zaburzenia neurodegeneracyjne mogą zostać postrzegane w kategoriach patologicznych zmian w obrębie sieci, które kreowane są przez współkomunikujące się ze sobą układy

¹ Takie ujęcie nawiązywać może do spostrzeżenia z badania z 29 listopada 2021 roku o hipotetycznym połączeniu AD z determinacją ze strony komórkowej energii mózgu a AD (Barthelson et al., 2021).

organiczne. Owa komunikacja odbywać się będzie za pomocą receptorów – co ściśle nawiązuje do układu endokannabinoidowego, będącego siecią rozsianych receptorów i spatologizowanego w chorobach degeneracyjnych. Receptory układu endokannabinoidowego są obecne zarówno w obrębie ośrodkowego układu nerwowego, jak i obejmują one jego obwodową część. Ponadto układ endokannabinoidowy partycypuje w synchronizacji i komunikacji międzysystemowej – również metabolicznej, glukozowo-lipidowej czy np. immunologicznej, a także ściśle wiąże się z dystrybucją fal mózgowych bądź wykazuje powiązania z progresją chorób neurodegeneracyjnych/degeneracyjnych (Calabrese et al., 2018; Cassani et al., 2018; Cecchetti et al., 2021; Cristino et al., 2020; Fowler, 2020; Kesner et al., 2020; Minichino et al., 2021; Santoro et al., 2021; Tirozzi et al., 2020).

W kontekście potencjalnego rozwoju sztucznej inteligencji, która może być postrzegana jako efekt procesu kreowania funkcjonalnego środowiska *equilibrium* z drobniejszych wzorców (niczym proces indukcji), wywód prowadzony będzie w znacznym stopniu przez pryzmat AD, gdyż jest określana globalną desynchronizacją funkcjonowania.

Połączenie pozornie wykluczających się zjawisk, takich jak rozwój sztucznej inteligencji i prawidłowość holistycznej neurodegeneracji AD, można zobrazować swoistą syntezą indukcji i dedukcji, które mają u źródła wspólny element. Rozwój sztucznej inteligencji określić można globalną synchronizacją procesów uwarunkowanych jakościową i homeodynamiczną komunikacją.

FUNKCJE NEUROKOGNITYWNE I INTELIGENCJA JAKO EFEKT WYŁADOWAŃ SIECI NEURONALNYCH

Motywym spajającym artykuł są prawidłowości wyrażone przez funkcje neurokognitywne i inteligencję postrzegane jako efekt wyładowań „sieci neuronalnych” (Gidon et al., 2020). Są to sfery, które wydają się łączyć neurokognitywistykę ze skoordynowanym funkcjonowaniem całego organizmu. Liczne badania wykazują związek między zaburzeniami funkcji oscylacyjnych oraz neurokognitywnych zarówno z zaburzeniami metabolicznymi, immunologicznymi, motorycznymi, jak i ogólnohomeostatycznymi (Hubbard et al., 2020; Lin et al., 2021).

INTELIGENCJA JAKO ZBIÓR ZAKODOWYWANYCH WZORCÓW MOCY OBLICZENIOWEJ

Inspirując się współczesnymi badaniami z obszaru neuronauk zorientowanymi na zjawisko inteligencji, można również spojrzeć na nią jako na sumę poszczególnych wyładowań neuronalnych (Gidon et al., 2020)².

Wyładowania te, współgrające z wpływem fal mózgowych na funkcjonowanie organiczne, mogą również determinować jakość układów fizjologicznych. Zgodnie z tą wizją

² Nowo odkrytym potencjałem czynnościowym wywoływanym w dendrytach i związanym z jonami wapnia towarzyszy wzmocnienie mocy obliczeniowej w mózgu, co uwidacznia się w rozwoju logicznych operacji XOR polegających na wprowadzeniu zdeterminowania procesu podejmowania decyzji jednoznacznością poprawnego rozwiązania. Kierując się analogią podejmowania decyzji, związaną z dokonywaniem jakościowej selekcji informacji, która może być obserwowana na polu społecznym, można natychmiastowo stwierdzić, że poprawa jakości podejmowania prawidłowych decyzji wiązać się będzie ze wzrostem poziomu inteligencji danej osoby.

inteligencję można ująć jako zbiór danych, który nierozzerwalnie wiązać się będzie z szeroko i wielowymiarowo ujętą pamięcią.

Pamięć ujmowana w kontekście funkcjonowania neurokognitywnego pojmowana może zostać przez pryzmat zjawiska sieci neuronalnych bądź neuronowych w wyniku ścisłego odwołania się do obserwacji kodowania informacji w powiązaniach między fazami pasm theta i gamma (Lisman, 2010; Lisman et al., 1995; 2013). Produktem końcowym nie jest konkretna zmienna wynikowa, lecz nieustannie dynamicznie iterowane właściwości wzorców pomiędzy fazami (nawiązuje to do idei matematycznej reprezentacji neuronalnych prawidłowości, która znajduje odzwierciedlenie w cyfryzacji neurologii ruchu – *computational neurology of movement* – Parr et al., 2021).

SIECI NEURONOWE WEDŁUG JOHNA HOPFIELDA

Rozważając sieci neuronowe przez pryzmat konceptu Hopfielda, zgodnie z którym stanowią one model agregacji danych pamięciowych, których jakość transferu poddawana jest determinacji ze strony wag u wejścia sieci neuronowej, zauważyć można wybijające się podobieństwo w analogii mechanizmu pamięci z AD. Wpływ ze strony wag na jakość lub performatywność procesu transferowania poszczególnych części informacji przekazywanych daną siecią (niczym fale światła światłowodem) może okazać się analogiczny do wpływu wywieranego przez parametry uzyskane z analiz częstości fal mózgowych na holistyczne funkcjonowanie neurokognitywne (które również można by zobrazować skomplikowaną siecią światłowodów pozostających w nieustannej interakcji ze sobą).

AD, będąc chorobą, która (zgodnie z współczesnymi obserwacjami) stanowi hipotetyczny efekt degradacji na skutek rekurencji neuronalnego błędu, odsyłać może do fenomenu wag ulokowanych u wejścia sieci neuronowej – gdyż degeneracja AD następuje stopniowo i zdaje się stanowić obraz wprost proporcjonalny do ilości odtworzeń błędu neuronalnego.

GPT-3 – NASTĘPNE GENERACJE MODELI JĘZYKOWYCH UMOŻLIWIAJĄCE SYNTEZĘ INTERDYSCYPLINARNYCH UMIEJĘTNOŚCI

Zobrazowaniem zarówno złożoności AD, jak i połączenia sieci neuronowych ze wzorcami degeneracji AD może być model językowy GPT-3 i hipoteza o rozwoju następnych generacji modeli językowych, które zgodnie z naukowymi przypuszczeniami będą w stanie łączyć dodatkowe zdolności, takie jak rozpoznawanie obrazów. AD obok zmian związanych z funkcjonowaniem pamięciowym obejmuje również degradację funkcjonowania językowego, kontekstowego czy np. orientacji czasoprzestrzennej. Warto uwypuklić w tym miejscu (dla zobrazowania połączenia AD z sieciami neuronowymi) (antytetyczne) powiązanie rozwoju sieci neuronowych ze spatologizowanymi strukturami mózgu, jak w tym przypadku płat skroniowy, przedczołowy czy istotnie wyeksponowane struktury hipokampu.

RESTRICTED BOLTZMANN MACHINE – HOMEODYNAMIKA

Obrazującym przykładem może być architektura *restricted Boltzmann machine*, w której przy braku zmiennej wynikowej istotą dynamicznej procesualności systemu jest

zachowanie jego energetycznej homeodynamiki (Hinton et al., 2006; Navamani, 2019; Upadhy et al., 2019).

Można również zaobserwować rozwój połączenia neurokognitywistyki (kontroli funkcji kognitywnych powiązanych z płatem przedczołowym, np. z pamięcią roboczą [*working memory*] oraz podejmowaniem decyzji) z wykorzystaniem potencjału architektury *deep learning* (Erguzel et al., 2020; 2020; Sangaiah, 2019; Vahid et al., 2020).

FALE MÓZGOWE I PRZETWARZANIE INFORMACJI – CIAŁO MODZELOWATE – SYNCHRONIZACJA MIĘDZYPÓLKULOWA

Wśród fal mózgowych występują pasma delta, theta, alfa, beta oraz dodatkowo mu i gamma. Fale mózgowie tworzą rytmiczne sekwencje i spontanicznie mieszają się ze sobą na różnych częstotliwościach. EEG jest dynamiczne i zmienia się wraz ze stanami fizjologii. Dlatego można je interpretować u pacjentów pozostających w stałym kontakcie z otoczeniem, w stanie spoczynku lub snu. EEG różni się w zależności od osoby. W przypadku konkretnej osoby zebrany pomiar EEG przeważnie nie odbiega znacząco, gdy zbierany jest w niewielkich odstępach czasu – istotnej zmianie ulega jednak wraz z procesami starzenia (Berman et al., 2015; Grundman, 2004; Kim et al., 2019; Klimova et al., 2017; Zeiler et al., 2014).

Rytm alfa to wzorzec, który odnosi się do wielu wymiarów uwagi wzrokowej jako aktywnego czuwania. Rytm alfa jest dominującą aktywnością, gdy pacjent jest odprężony psychicznie i fizycznie, ale nie pozostaje nawet w lekkim śnie.

U osób dorosłych, którzy pozostają w stanie odpoczynku, występuje zwłaszcza w okolicy potylicznej. Osłabia się przy otwieraniu oczu, ale nawet ta wrażliwość (jej zmienność nasilenia) zależy od różnic indywidualnych.

Rytm alfa waha się od 8–9 Hz do 11–12 Hz – u 70% osób po dwudziestym roku życia. Jedna osoba na sto ma powolny/zmienny i powolny bądź zmienny rytm alfa 4–5 Hz w tylnym obszarze mózgu. A szybko zmieniający się rytm, o częstotliwości 14–20 Hz, jest jeszcze rzadszy niż powolny rytm.

Inspirując się badaniami nad aktywnością pasma alfa i jego zaangażowania w procesy zarówno selektywności dystraktora podczas funkcji związanych z procesami uwagowymi, jak i procesy umożliwiające wgląd we własne wnętrze, dostrzec można wielowymiarowe zaangażowanie alfy w funkcjonowanie kognitywne – czy to pod względem formowania pamięci czy jej funkcjonowania, czy pod względem istnienia procesów powiązanych z kreatywnością bądź stanem wędrówki umysłu (*mind-wandering*). Stan wędrówki umysłu współgra z funkcjonowaniem osób z zaburzeniami takimi jak ASD i AD oraz ze stanem kreatywności/interpretacji bodźców percepcyjnych w środowisku artystów (wśród których znajdują się mogą użytkownicy marihuany lub psychodelików, dla których psychodeliki pełnią rolę stymulacji „pola percepcyjnego doświadczenia” świata zewnętrznego).

Dokonywanie jakościowej interpretacji bodźców wewnętrznych czy zewnętrznych wydaje się korespondować z potencjalnym wpływem pasma alfa na orientację czasoprzestrzenną oraz myślenie twórcze. Obydwa stany umysłu wydają się łączyć się wymiary, zarówno artystyczny,

obarczony symptomami chorób neurodegeneracyjnych czy wymiar szeroko postrzeganego związku hipokampa z ciałem migdałowatym (a w efekcie z neurogenezą hipokampa).

Liczne badania (Agnoli et al., 2019; Fink et al., 2014; Jensen et al., 2010; Klimesch 1999, Klimesch et al., 2007,) dotyczące weryfikacji rytmu alfa i współzaangażowanych obszarów mózgu przy użyciu metodologii EEG lub jej kombinacji z fMRI wykazały poniekąd odmienne role rytmu alfa ERS (Event-Related Synchronization) w okolicy czołowej i skroniowo-ciemieniowej (Benedek et al., 2012; 2014). Czołowa aktywność alfa ERS może odzwierciedlać funkcje wykonawcze, takie jak hamowanie niepożądanych wspomnień (jak np. oczywiste i pospolite pomysły).

Wyniki analiz zebranych pomiarów EEG ujawniły, że wzorzec aktywności pasma alfa współgrał ze wzrostem mocy alfa podczas DT (*dream-thinking*) (Baldwin et al., 2017; Zhang et al., 2018).

Zmiany oscylacyjne pasma alfa, obserwowane podczas generowania powtarzalnych alternatywnych odpowiedzi, przypominały kreatywne i oryginalne odpowiedzi. W szczególności, jeśli chodzi o oryginalność odpowiedzi, zaobserwowano różnicę w zmianie mocy alfa między pierwszą a następnymi trzema odpowiedziami.

JEDNOCZESNA SYNCHRONIZACJA I DESYNCHRONIZACJA PODCZAS GENEROWANIA SŁÓW

Podczas generowania kolejnych sekwencji wypowiedzi odnotowano charakterystyczną desynchronizację rytmu alfa z obszaru płatów czołowych oraz lewych obszarów płatów skroniowych i ciemieniowych. Generowanie kolejnych odpowiedzi wiązało się również z synchronizacją rytmu alfa, szczególnie w prawej części centralnej, skroniowej i ciemieniowej.

Wykazano, że desynchronizacja rytmu alfa w lewym i prawym płacie czołowym podczas pierwszego okresu generowania pomysłów jest silniejsza u tych, którzy osiągnęli niską oryginalność, a zatem u tych, którzy prawdopodobnie nie są w stanie pomyślnie przeprojektować informacji związanych z obiektem i są przywiązani do wyszukiwania informacji z przeszłości – z pamięci długotrwałej.

Podczas snu rytm alfa zastępowany jest wolniejszymi rytмами. Theta to zakres częstotliwości od 4 Hz do 7 Hz. Fale theta są powszechne u dzieci w większości środkowej części mózgu. Mogą również pojawić się u zdrowych dorosłych na początku snu lub w stanie ekspresji i ekscytacji. Fale theta u budzących się dorosłych wskazują na nieprawidłowości. Jedna trzecia młodych dorosłych charakteryzuje się stłumioną aktywnością theta do 6–7 Hz w obszarach czołowych. Aktywność theta jest widoczna podczas wykonywania zadań związanych z aktywacją umysłową, ale można ją zobaczyć wyraźniej podczas lekkiego snu z powodu osłabienia bodźców zewnętrznych. Obustronna lub uogólniona polimorficzna aktywność theta wskazuje na normalną senność dorosłych lub encefalopatię. Aktywność theta jest naturalna u niemowląt (Rangayyan, 2002; Stern et al., 2013).

POWIĄZANIE FAL MÓZGOWYCH Z KONSOLIDACJĄ PAMIĘCI

Zgodnie z teorią Lismana i Idiarta (Lisman, 2010; Lisman et al., 1995; 2013), związaną z naukową obserwacją zjawiska formowania się pamięci w kontekście czynności funkcjonalnej

fal mózgowych pasm theta i gamma pojawia się hipoteza o wyraźnym znaczeniu zmienności faz, w jakich można zauważyć fale mózgowe. Fazowanie, kąt nachylenia i wektor wynikowy w zależności od kąta nachylenia określa moc wypadkową przyczynowo-skutkową i wypadkową amplitudę sygnału. W odniesieniu do prawidłowości neurobiomechanicznych warto zwrócić uwagę na przestrzenne relacje zależności neuronalnych, które wyłaniają się z architektury określonego wzorca oscylacji. Architektura ta zdaje się determinować pojemność pamięci. A zatem przestrzenne relacje zależności neuronalnych powinny oddziaływać na jakość przetrzymywania informacji w czasie oraz na pełnowymiarowe formowanie pamięci.

WPLYW CHOROÓB NEURODEGENERACYJNYCH NA MECHANIZM PAMIĘCI

Choroby neurodegeneracyjne, w tym AD, charakteryzują się deficytem i patologizacją procesów poznawczych. Wiąże się to z zaburzeniami codziennego funkcjonowania, prowadzącymi do postępującej patologizacji globalnego funkcjonowania, na przykład różnych wymiarów sieci interakcji organicznych. Jakość procesów pamięciowych, w tym zdolność do przechowywania informacji w pamięci roboczej i utrzymywania jej w czasie wiąże się z aktywnością fal mózgowych, która zdaje się determinować wymiar innych warstw funkcjonowania. Wymiar motoryczny, wymiar sensomotoryczny lub związany zarówno z percepcją czasoprzestrzenną, jak i automatycznym postrzeganiem bądź percepcją położenia ciała w przestrzeni. Sprzężenie theta–gamma jest kodem nerwowym, którego zaburzenia są zarówno obserwowalne, jak i mają współdecydującą właściwość zwiększania rozwoju objawów chorobowych.

OBCIĄŻENIE PAMIĘCI. Dezaktywacja lub stłumienie przetwarzania informacji wiąże się z oscylacyjną aktywnością mózgu w paśmie alfa EEG (około 10 Hz) (Craik et al., 2019; Romei et al., 2010; Sauseng et al., 2009). Zauważono, że wraz ze wzrostem obciążenia pamięci pojawiała się zwiększona potrzeba tłumienia nieistotnych informacji – zgodnie z hipotezą moc pasma alfa ipsilateralnego zwiększała się wraz ze wzrostem obciążenia pamięci.

Ponadto wykazano, że synchronizacja faz między theta i wysokimi oscylacjami gamma reaguje tylko na zatrzymanie odpowiednich informacji, niezależnie od ilości nieistotnych informacji, które współwystępują.

Co więcej, sprzężenie theta–gamma jest ściśle związane z amplitudą alfa, zapewniając selekcję dystraktorów wśród bodźców wzrokowych, w których moc alfa jest ustawiona jako marker wzrokowo-przestrzennej orientacji uwagi i tłumienia w normoksji i hipoksji (Zani et al., 2020). Wyniki powyższego badania pokazują, że orientacja uwagi wiąże się z desynchronizacją alfa i że prawostronna synchronizacja alphy w sytuacji hipoksji może służyć zarówno wysiłkowi utrzymania uwagi w czasie, jak i ogólnemu tłumieniu funkcji latencji uwagi.

WZORCE ALFY. Omawiając aktywność fal mózgowych pasm theta, gamma, alfa w kontekście funkcji pamięciowych i zazębiając to z desynchronizacją czy zaburzeniami funkcjonowania pamięci w AD, warto bliżej przyjrzeć się wykorzystaniu wzorców alfy, która wpływając na funkcje uwagowe i determinowanie filtrowania dystraktorów informacyjnych, wydaje się współodgrywać znaczącą rolę w funkcjonowaniu kognitywnym (Gola et al., 2013).

Dodatkowo rytm alfa, biorąc aktywny udział w procesach „wędrowki umysłu (Adrian et al., 1934; Clay et al., 2020; Compton et al., 2019; Jin et al., 2019; Smallwood et al., 2015; Stretton et al., 2012; Tanveer et al., 2020; Thut, 2006; Zedelius et al., 2015), czyli stanów introjekcji funkcji uwagowych do wnętrza umysłu, które cechują AD czy ASD, i determinując funkcje filtrowania informacji (również obciążone błędem w chorobach neurodegeneracyjnych) – wykazuje olbrzymi potencjał rozwojowy. Potwierdzeniem tezy zdają się badania z obszaru wirtualnej rzeczywistości (VR) czy uczenia maszynowego (ML) czerpiące z potencjału alfy.

Badaniem związanym z dystrybucją alfa i jej mocą lub synchronizacją/desynchronizacją w kontekście wirtualnej rzeczywistości (VR) jest badanie mocy alfa jako modulatora zmian uwagi podczas wykonywania zadań związanych z funkcjami uwagi skupiającymi się na mocy alfa EEG, modulowanej przez zmiany uwagi podczas zadań poznawczych i zanurzenie w VR (Corti et al., 2018; Deng, 2014; Li et al., 2017; Magosso et al., 2019; Roy et al., 2019). W obu sesjach prezentowanych w tym badaniu faza relaksacji przed zadaniem charakteryzowała się dużą przewagą mocy alfa nad tylną częścią mózgu i stopniowym spadkiem w kierunku czołowo-centralnym. Podczas fazy zadania moc alfa wykazywała zmniejszenie, wyraźniej zauważalne w obszarze tylnym niż w obszarze czołowo-środkowym; ponadto zadanie arytmetyczne współgrało z silniejszym spadkiem mocy alfa niż zadanie odczytu liczb.

Omawiając i podkreślając holistyczny wpływ fal mózgowych na funkcjonowanie organizmu (np. procesy wewnątrzkomórkowe, związane z relacyjnością między jądrem komórkowym i retikulum endoplazmatycznym (ER), współodpowiedzialnym za fundamentalne procesy syntetyzowane białek czy procesy związane z prawidłowością występowania sytuacji stresowej w obszarze ER [*stress ER*]). Stres ER wynika z chronicznego zaburzenia homeostazy ER (He et al., 2020), co przede wszystkim charakteryzuje się akumulacją nieprawidłowych białek, zaburzających równowagę zdolności ER do fałdowania białek, aby nadążać za zapotrzebowaniem komórkowym (Banhegyi et al., 2007; Yang et al., 2021)), który (ów wpływ fal mózgowych) przez zaprzeczenie wyraźnie widoczny jest w procesach degradacji w chorobach neurodegeneracyjnych, warto spojrzeć na ciało modzelowate, które pośredniczy zjawisku synchronizacji. Zaprzeczenie tego zjawiska, czyli desynchronizacja, zdaje się cechować choroby neurodegeneracyjne.

CIAŁO MODZELOWATE (*CORPUS COLLOSUM*) – SYNCHRONIZACJA MIĘDZYPÓLKULOWA. Jedną z prac nawiązujących do obszaru modzelowatego i jego związku z synchronizacją półkulową oraz ze znaczącym powiązaniem z pasmem alfa, gamma, theta u pacjentów z AD, jest (Pogareł, 2005) badanie korelacji między rozmiarem ciała modzelowatego a międzypółkulową spójnością EEG. Korelacje te zostały zbadane jako miary łączności międzypółkulowej u pacjentów z AD. Regionalne korelacje między rozmiarem ciała modzelowatego a koherencją EEG sugerują, że spadek łączności międzypółkulowej w AD wynika z określonej utraty neuronów asocjacji korowej zaangażowanych przez ciało modzelowate.

Pole przekroju poprzecznego ciała modzelowatego było znacznie zmniejszone u pacjentów z AD w porównaniu z grupą kontrolną. Tylna koherencja międzypółkulowa (częstotliwości alfa i beta) korelowała istotnie z wielkością obszaru tylnego ciała modzelowatego, a koherencja przednia (częstotliwości delta, theta i alfa) z wielkością przedniego obszaru ciała modzelowatego u pacjentów z AD.

Pozostając w obrębie synchronizacji i AD, warto jeszcze wspomnieć o kannabinoidach, które wykazują funkcje synchronizujące (nie tylko fale mózgowy, jak w przypadku epilepsji), ale również stężenia koneksyny 43, której agregacja koresponduje z rozwojem AD.

SYNCHRONIZACJA I DESYNCHRONIZACJA FAL MÓZGOWYCH

Poniższa część rozpocznie się badaniem z obszaru synchronizacji i desynchronizacji, których koordynacja determinuje funkcjonowanie kognitywne. Analiza częstości aktywności mózgu, np. wydobywająca fazę czy amplitudę – może odsyłać do obserwacji Lisman i Idiart, gdzie pamięć i przetwarzanie informacji zdeterminowane jest fazą i amplitudą pasm theta oraz gamma.

MODEL SYNC/DESYNC

Niniejsze badanie (Parish et al., 2018) koncentruje się bezpośrednio na udanym kodowaniu i odzyskiwaniu pamięci.

Wykazano, że desynchronizacja oscylacji alfa (10 Hz) jest zaangażowana w tworzenie pamięci i przewidywanie znaczącego kodowania pamięci.

Jednak w odniesieniu do działania procesów uczenia się stwierdzono, że pojawia się związek w obszarze hipokampa, polegający na istnieniu zjawiska synchronizacji w oscylacji theta (4 Hz), i proces uczenia się zależy od fazy theta.

W pracy Parisha et al. (2018) przedstawiono zastosowanie *spiking neural networks* (model Sync/deSync) w obrębie układu kory nowej i hipokampa. Symulowany hipokamp uczy się przez zaadaptowaną regułę plastyczności zależną od czasu impulsu, w której zmiana wag modelu modulowana jest przez fazę zewnętrznie generowanej oscylacji theta. Dodatkowo włączony został globalny pasywny spadek wag modelu, który jest również modulowany przez fazę theta.

Model Sync/deSync wykazuje zależne od fazy theta długotrwałe nasilenie i długotrwałą depresję. I dostarcza obserwacji, że zarówno desynchronizacja neokorowej alfa, jak i synchronizacja hipokampa theta są niezbędne do pomyślnego kodowania i odzyskiwania pamięci.

Tworzenie pamięci można opisać w dwóch aspektach dotyczących synchronizacji/desynchronizacji: (1) w korze nowej neurony muszą wyrwać się z oscylacji alfa, aby reprezentować bodziec (tj. desynchronizacja alfa); (2) w hipokampie wyładowania neuronów w paśmie theta ułatwiają tworzenie wspomnień (tj. theta synchronizuje).

Model Sync/deSync wyjaśnia, że udane tworzenie pamięci charakteryzuje się zmniejszoną wartością alfa kory nowej i wzrostem theta w obszarze hipokampa.

SYGNAŁ NEURONALNY

Komunikacja między neuronami i wewnątrz nich ma kluczowe znaczenie dla funkcjonowania układu nerwowego, począwszy od rozwoju aż po starzenie się bądź czy to w zdrowiu, czy w chorobie (Kamiński et al., 2017). Odnotowano, że trwała aktywność rozproszonych sieci

neuronalnej (przy braku pewności, który obszar mózgu jest głównym obszarem zaangażowania) jest przypuszczalnym mechanizmem utrzymywania informacji w pamięci roboczej, a trwała aktywność neuronów hipokampa i ciała migdałowatego była specyficzna dla bodźca i była zarazem predyktorem zawartości pamięci.

Zatem zauważyć można bezpośrednie przełożenie jakości neuronalnych wyładowań na jakość funkcjonowania również na polu społecznym, co uwidaczniać się może w jakości prowadzonej komunikacji. A w konsekwencji, poprzez determinowanie przekazywania informacji (które ulega zaburzeniom w AD) wiązać się może z wymiarem funkcjonowania nie tylko kognitywnego. Z kolei jako hipotezę tej ewentualności, wysnuć można tezę o związku AD z fenomenem sztucznej inteligencji poprzez element wspólny w postaci pamięci postrzeganej w kategorii neuronalnego przekazu danych.

W ostatniej dekadzie nastąpił ogromny postęp w wiedzy na temat molekularnych, komórkowych i systematycznych szlaków sygnałowych w układzie nerwowym. Dokonano znaczących przełomów w badaniach dotyczących szlaków leżących u podstaw neurogenezy (Urban et al., 2014), uzależnień (Robison et al., 2011; Russo et al., 2010) i zaburzeń ze spektrum autyzmu (Ebert et al., 2013; Mullins et al., 2014), a także patofizjologii i leczenia zaburzeń nastroju (Chaudhury et al., 2015).

Zjawisko komunikacji neuronalnej wraz z postrzeganiem mózgu jako wytraconego z równowagi systemu biofizycznego, podlegającego przepływowi energii, entropii i informacji odwołuje również do zjawiska wykorzystania aplikowania mechaniki kwantowej dla ekstrakcji właściwości ulokowanych w sygnale EEG (Li et al., 2020; YaoChong et al., 2021).

Uczenie maszynowe kwantowe (QML) to rozwijająca się dziedzina badań poświęcona opracowywaniu i wdrażaniu algorytmów kwantowych, które mogą umożliwić szybsze uczenie maszynowe niż w przypadku klasycznych komputerów. Rozwijająca się dziedzina QML ma ogromny potencjał, aby istotnie pomóc w problemach i zakresie sztucznej inteligencji.

W badaniu tym wykorzystano również prawidłowość entropii w celu dokonania jakościowej klasyfikacji danych sygnału neuronalnego.

ELEKTRYCZNA I SYNAPTYCZNA INTEGRACJA GLEJAKA Z OBWODAMI NERWOWYMI

Badaniem (Venkatesh et al., 2019), które zdaje się ściśle nawiązywać do postrzegania ośrodkowego układu nerwowego jako zamkniętego homeodynamicznego układu posiadającego olbrzymi potencjał rozwojowy, jest badanie wykazujące znaczenie sygnału neuronalnego przy determinowaniu wzrostu komórek – komórek nowotworowych, które przechwytyją sygnał zdrowych neuronów.

Jest to badanie naukowców ze Stanfordu wykazujące, że glejowe komórki nowotworowe wchodzi w interakcję ze zdrowymi komórkami nerwowymi przez przechwytywanie ich niespatologizowanego sygnału neuronalnego. Dzięki temu uzyskują one możliwość rozrostu, czemu towarzyszy zauważalna synaptogeneza.

Z kolei *Study of Artificial Intelligence Models Applied to the Analysis of Electroencephalograms in Alzheimer's Disease* jest badaniem, które wykazuje związek między aktywnością

mózgu a rozwojem architektury sieci neuronowych w oparciu o algebraiczne wzorce uzyskane z weryfikacji narzędziem EEG (Salomon et al., 2020).

W badaniu zorientowanym na detekcję AD, przy wykorzystaniu wzorców EEG i obserwacji z analiz *higuchi fractal dimension* oraz *power spectral density* (gęstość widmowa mocy), zastosowano architekturę sieci Feedforward Neural Network i uzyskano dokładność 99,8%.

Zarówno *higuchi fractal dimension*, jak i *power spectral density* to miary spektralnej analizy częstości traktującej sygnał EEG jako zbiór częstości, który po dokonaniu obliczeń i rozkładu na czynniki wykazuje fundamentalne i charakterystyczne właściwości/parametry dla danej trajektorii sygnału EEG.

W badaniu (Amini et al., 2021) opartym na architekturze konwolucyjnych sieci neuronowych do diagnozy AD przy wykorzystaniu (*time-dependent power spectrum*) sygnału EEG w przypadku podejścia spłotowego sieci neuronowej dokładność prawidłowo diagnozowanego pomiaru wynosi 82,3%. 85% dla przypadków łagodnych zaburzeń poznawczych (MCI), a 89,1% dla AD i 75% dla zdrowej populacji.

Badanie (Hata et al., 2021) wykazało, że aplikacja uczenia głębokiego umożliwiła dokonanie wyraźnej dystynkcji między danymi EEG zebranymi od pacjentów z demencją a uzyskanymi od zdrowych ochotników. Wykorzystując głębokie uczenie wraz z pomiarami EEG, możliwy do osiągnięcia i realizacji staje się cel diagnostyki przesiewowej w kierunku badań zorientowanych na detekcję chorób otępiennych. Wyniki wykazały wysokie dokładności różnicujące pomiędzy HV (grupą kontrolną – *healthy volunteers*, $N = 55$) a pacjentami z otępieniem, osiągając 81,7% (w porównaniu z AD, $N = 101$), 93,9% (w porównaniu z DLB – *Lewy bodies dementia*) i 93,1% (w porównaniu z iNPH – *idiopathic normal pressure hydrocephalus*, $N = 60$).

DESYNCHRONIZACJA PASMA THETA–GAMMA JAKO POTENCJALNY MEDIATOR AD

W badaniach (Goodman et al., 2018) polegających na weryfikacji TGC (*theta–gamma coupling*) jako istotnego elementu pamięci w kontekście AD przeprowadzono badanie zadaniowe N -back, podzielone na dwie podgrupy zadaniowe: 1-back i 2-back.

Zadanie N -back to werbalne zadanie pamięci roboczej, które wymaga od uczestników określenia, czy bodziec prezentowany na monitorze komputera jest taki sam czy inny od bodźca prezentowanego w zadaniu, będącym N razy wcześniej wykonywanym.

W obu częściach zadania istniała wyraźna różnica między TGC u uczestników z AD a uczestnikami z MCI (łagodne upośledzenie poznawcze) lub w stosunku do grupy kontrolnej, która była zdrowymi uczestnikami.

Poziom TGC u osób z AD był znacznie obniżony w porównaniu z obiema równoległymi grupami. Z drugiej strony, co wydawało się ważnym spostrzeżeniem, zarówno moc theta, jak i moc gamma w poszczególnych grupach nie różniły się istotnie. Ponadto w badaniach niedocelowych uczestnicy z AD wykazywali znaczące zmniejszenie TGC w stosunku do zdrowych uczestników, podczas gdy nie zaobserwowano żadnych istotnych różnic między AD i MCI, a także związku MCI ze zdrowymi uczestnikami.

Fale mózgowe, które przemieszczają się wzdłuż układu okołonерowego ciała (*the perineural system of the body*) i mieszają się z ciągłym prądem wyładowań (*continuous discharge current*), są dynamicznym wyznacznikiem zapewniającym stan homeodynamiki. Powstały wektor homeostazy jest siłą będącą wypadkową zrównoważonych sił, wynikająca z jednoczesnych procesów organicznych i jest kluczowym składnikiem naprawy tkanek i prawdopodobnie wszystkich wewnętrznych procesów regeneracyjnych.

Zatem rytmiczne oscylacje sieci neuronowych mogą być rodzajem zachowania synchronicznego, które odgrywa ważną rolę w systemach neuronowych.

Synchronizacja w układzie nerwowym jest ważną podstawą przetwarzania informacji sensorycznych i funkcji motorycznych, ale występowanie synchronizacji/desynchronizacji w niektórych określonych obszarach mózgu może być również związane z rozwojem np. epilepsji czy choroby Parkinsona (Abbassian et al., 2016; Del Rey et al., 2018; Ferreira et al., 2020).

Sama jakość funkcjonowania poznawczego, a także poprawność wykonywania zadań zależą od synchronizacji oscylacyjnych odpowiedzi neuronalnych w układzie wzrokowym (Köster et al., 2018), co wydaje się jednym z głównych fundamentów synchronizacji funkcjonowania (Cushman et al., 2008; Sauseng et al., 2009). Również poprzez ruchy gałek ocznych, najbardziej dostępnych (w bezpośredniej weryfikacji i oglądzie) elementów układu wzrokowego i układu nerwowego, wraz z aktywnym zaangażowaniem uwagi może nastąpić synchronizacja półkulowa. Znaczenie gałek ocznych wydaje się widoczne także w sytuacji torowania neuronalnego, np. w przypadku rehabilitacji neurologicznej, ponieważ pozostają w harmonii z uwagą skierowaną na ten aspekt obszaru ciała, który z powodu urazu sprawia wrażenie, że utracił swoją neuronalną reprezentację.

Współczesne metody analizy szeregów czasowych zostały opracowane w celu zbadania aktywności oscylacyjnej związanej z zadaniami i wydajnością oraz jej synchronizacji. Badania oparte na powyższych technikach wykazały, że synchronizacja oscylacji w pasmach beta i gamma jest zaangażowana w różne funkcje poznawcze (Jeong et al., 2004; Radivojević et al., 2020) – grupowanie percepcyjne, selekcja bodźców zależnych od uwagi, kierowanie sygnałami w rozproszonych sieciach korowych, integracja, praca pamięci i świadomość percepcyjna. Pewne zaburzenia aktywności neuronalnej mózgu – schizofrenia, epilepsja, autyzm, AD i choroba Parkinsona – są związane z nieprawidłową synchronizacją neuronalną. Dane sugerują bliskie powiązania między nieprawidłowościami w synchronizacji neuronalnej a dysfunkcją poznawczą.

Rytm fal mózgowych związany jest zarówno z funkcjonowaniem poznawczym, dzięki czemu może być wykorzystany do wykrywania chorób poznawczych, choć nie tylko zorientowanych na wymiar poznawczy, jak i z realizacją terapii wspomaganą treningiem poznawczym wraz z normalizującym zjawiskiem biofeedbacku.

Biofeedback EEG to zabieg, który pozornie powstał jak Feniks z popiołów pod nowym tytułem NeuroFeedback (NF). Obecnie staje się coraz bardziej popularny jako jedyna lub uzupełniająca metoda leczenia szerokiej gamy zaburzeń, z których wiele pozostaje opornych na bardziej tradycyjne terapie.

Chociaż istnieją doniesienia o niemal cudownych wynikach z minimalnymi lub żadnymi skutkami ubocznymi, praktycy NF często wyrażają sceptycyzm i obiektywizm, ponieważ ich

wyniki są odrzucane przez medycynę głównego nurtu, psychologię i edukację. Podważają zarzuty braku akceptacji jako dowód, że leczenie nieprawidłowości w elektrycznych aspektach elektrochemicznego funkcjonowania mózgu może być co najmniej tak samo skuteczne, jak leczenie zaburzeń równowagi chemicznej.

Biorąc pod uwagę szybko rosnące dowody naukowe na neuroplastyczność, w tym wpływ ośrodkowego układu nerwowego na funkcjonowanie układu odpornościowego i rytmiczne prawidłowości przekazywania dużych ilości informacji do mózgu, nie wydaje się nierozsądne, by oczekiwać, że zmodyfikowane rytmy ośrodkowego układu nerwowego mogą mieć głęboki wpływ na aspekt zdrowia i tempa uczenia się (a równolegle, by ta zależność i sam efekt powstały po oddziaływaniu zmodyfikowanych oscylacji był wprost proporcjonalny do siły oddziaływania powyższych czynników na jakość funkcjonowania neurokognitywnego wraz z parametrami analiz częstości fal mózgowych).

Poznawcze przetwarzanie informacji neuronalnej w korze mózgowej jest ściśle związane z aktywacją dużej liczby neuronów, które dynamicznie i stale pozostają w synchronicznej współpracy płatów i struktur mózgu. Wzorce aktywności neuronalnej wymagają ścisłej integralności w zsynchronizowanych i skoordynowanych regionach neuronowych. Synchronizacja czasu jest rodzajem regularności neuronalnej leżącej u podstaw tych wzorców poznawczych.

W korze wzrokowej synchronizacja objawia się wybiórczo między odpowiedziami aktywności neuronalnej i wiąże się z potrzebą zintegrowanej generacji, aby zapewnić ciągłość jakościowej transmisji danych.

Pasma theta i alfa, stanowiące rozproszony sygnał nerwowy kory nowej ludzkiego mózgu, są fundamentalnym zaangażowaniem w performatywność funkcjonowania poznawczego. Z artykułu *Theta i Alpha Oscillations are Traveling Waves in the Human Neocortex* (Zhang et al., 2018) wyłania się obserwacja oscylacji o częstotliwościach od 2 Hz do 15 Hz. „Te oscylujące klastry wykazywały przestrzenne gradienty fazowe, co wskazuje, że tworzyły fale biegnące, które rozchodziły się z prędkością $\sim 0,25\text{--}0,75$ m/s”.

Ciekawym badaniem, które można uznać za synchronizację obu aspektów – pamięci z pamięcią długookresową (LSTM) i zaburzeń neurologicznych – może się okazać zastosowanie sieci LSTM przez predyktor OPTICAL do klasyfikacji fal mózgowych (Kumar et al., 2019).

Głębokie uczenie zyskało ostatnio szerokie zainteresowanie w dziedzinie przetwarzania sygnałów. Sieć LSTM to powtarzająca się sieć neuronowa składająca się z warstw LSTM, posiadająca zdolność do selektywnego zapamiętywania ważnych informacji przez dłuższy okres i jest najczęściej używana do przewidywania sekwencji.

OPTICAL wykorzystuje pojedynczy filtr środkowoprzepustowy Butterwortha z częstotliwościami odcięcia 7–30 Hz. Obiecujące dziesięciokrotne wyniki krzyżowej walidacji uzyskano za pomocą OPTICAL, który został oceniony z użyciem zestawu danych BCI Competition IV 149 i GigaDB. OPTICAL wykazał poprawę wyników klasyfikacji (osiągając średni wskaźnik błędnej klasyfikacji 17,48% i 31,81% odpowiednio dla zestawu danych BCI Competition IV 1 i GigaDB) i może być korzystny w opracowywaniu ulepszonych systemów BCI do rehabilitacji. Zbiór danych GigaDB, który zapewnia również nagrania dla sygnałów stanu spoczynku i innych sygnałów niezwiązanych z zadaniami, został wykorzystany do wykazania skuteczności OPTICAL do implementacji w czasie rzeczywistym. W jej przypadku osiągnięto

średni współczynnik błędnych klasyfikacji wynoszący 17,78% w przypadku pięćdziesięciu dwóch badanych korzystających ze zbioru danych GigaDB.

SVM, który został użyty w tym badaniu jako klasyfikator z radialną podstawą funkcji jądra, jest nadzorowaną techniką uczenia się, którą można wykorzystać zarówno do klasyfikacji, jak i regresji. Algorytm SVM znajduje hiperpłaszczyznę, która maksymalizuje separację wektorów nośnych.

Proponowany predyktor OPTICAL obejmuje optymalizację hiperparametrów sieci LSTM przy użyciu optymalizacji Bayesa. Precyzyjna optymalizacja hiperparametrów sieci LSTM zaowocowała dalszą poprawą współczynnika błędnej klasyfikacji o 1,78% i 1,42% odpowiednio w zestawie danych BCI Competition IV 1 i GigaDB. Przeprowadzono eksperymenty w celu określenia liczby warstw LSTM i liczby jednostek ukrytych w każdej warstwie LSTM w celu uzyskania optymalnej wydajności. Naukowcy ograniczyli swoje eksperymenty do maksymalnie dwóch warstw LSTM i maksymalnie 200 jednostek ukrytych w każdej warstwie LSTM, aby utrzymać złożoność obliczeniową systemu na niskim poziomie. Okazało się, że użycie dwóch warstw LSTM dało lepsze wyniki w porównaniu z użyciem pojedynczej warstwy LSTM.

Bardzo pożądane są systemy interfejsu mózg–komputer (BCI) posiadające zdolność klasyfikowania fal mózgowych z większą dokładnością. BCI stało się znaczącą dziedziną badań, ponieważ jest coraz częściej wykorzystywane w grach i rehabilitacji po udarze do przekładania sygnałów mózgowych z wyobrazonego zadania na zamierzony ruch sparaliżowanej kończyny. Ponadto prowadzone są również badania BCI w celu wykrycia z wyprzedzeniem, czy dana osoba będzie cierpieć na atak napadu (Zahra et al., 2017), aby zapobiec poważnym obrażeniom.

Ze względu na niski koszt i łatwość użycia elektroencefalografii (EEG) oraz to, że nie potrzebuje ona żadnej operacji wymaganej przez czujniki inwazyjne, BCI wydaje się rozsądną i potencjalną podstawą do jej wykorzystania. Stosowanie czujników nieinwazyjnych zbliża się do wymaganego technologicznie postępu i przekładają one działania neuronalne na znaczące informacje, które można wykorzystać do napędzania zależnych od aktywności robotów neuroplastycznych lub rehabilitacyjnych.

Możliwość klasyfikowania różnych zadań z większą dokładnością za pomocą sygnału EEG będzie nie tylko korzystna dla obszaru doskonalenia technologii gier komputerowych i obszaru doskonalenia technik rehabilitacyjnych, ale może również być skuteczna w wykrywaniu chorób lub nieprawidłowych zachowań, takich jak napady epileptyczne, bezdech senny, fazy snu i wykrywanie senności.

HIPOKAMP – WZORCE FAZ ALFA

Poprzez odniesienie do funkcjonowania struktur hipokampu, np. pamięci czasoprzestrzennej czy orientacji przestrzennej, można zauważyć znamienne połączenie między weryfikacją koherencji fal mózgowych a zastosowaniem architektury *spike recurrent neural networks* w celu wyuczenia sieci neuronowych wzorców przestrzennych (Laje et al., 2013), aby osiągnąć precyzyjną wielozadaniowość (Palsson et al., 2018; Perez et al., 2015; Radford, 2016).

Zarówno zdolność do multitaskingu, jak i orientacja przestrzenna wiążą się z jakością funkcjonowania neurokognitywnego, które wykazuje znaczące upośledzenie w AD (Magosso et al., 2019; Majoros et al., 2019; Noda et al., 2017; Petersen, 2004).

Z badania (Babiloni et al., 2020), które porusza kwestię zaburzeń demencyjnych w grupach pacjentów z ADD (*Alzheimer's disease dementia*), LBD (*Lewy body dementia*) i PDD (*Parkinson disease dementia*), wyłania się jedno ze znaczących spostrzeżeń, dotyczące aberracji w obrębie dystrybucji pasma alfa.

W badaniu tym dzięki statystycznym weryfikacjom wyników funkcji *power spectral density* oraz *phase lag index* pasma alfa odnotowano wyraźną i znaczącą różnicę między ADD a pozostałymi grupami. Wyróżniającymi markerami rezerwy neurofizjologicznej u pacjentów z ADD może być dramatyczny spadek zarówno synchronizacji/desynchronizacji, jak i funkcjonalnej łączności korowej w tylnych obszarach mózgu będących źródłem pomiaru rytmu alfa.

Obszar pod krzywą ROC (AUC, AUROC) wykazywał dokładność klasyfikacji między osobami Nold a chorymi (uwzględniono tylko wartości $>0,7$). Międzypółkulowe i śródpółkulowe LLC (funkcjonalna opóźniona łączność liniowa) w szeroko rozpowszechnionych źródłach (*interhemispherically and intrahemispherically, with more discrimination*) delta były wyższe w grupie ADD i nieoczekiwanie w grupach DLB i PDD. LLC zmniejszyła się dramatycznie w szeroko rozpowszechnionych źródłach alfa w ADD, znacznie w DLB i umiarkowanie w grupie PDD. Co więcej, międzypółkulowa LLC w szeroko rozpowszechnionych źródłach alfa wykazała niższe wartości w ADD i DLB niż w grupach PDD.

AUROC dla rozwiązań LLC w źródłach alfa wykazał lepszą dokładność klasyfikacji dla odróżnienia ADD od osobników Nold (0,84) niż dla Nold od DLB (0,78) i Nold od PDD alfa (0,75). Odkrycia te sugerują, że funkcjonalna łączność korowa zarówno w źródłach delta, jak i alfa może ujawnić bardziej upośledzoną rezerwę neurofizjologiczną (*a more compromised neurophysiological reserve*) w ADD niż DLB. Efekt ten może występować międzypółkulowo i śródpółkulowo z większym rozróżnieniem między grupami ADD i DLB międzypółkulowo.

Można zatem sformułować hipotezę, że wykorzystanie wzorców faz poszczególnych pasm fal mózgowych może posłużyć zarówno jako efektywne narzędzie diagnostyczne (np. Seo et al., 2020; Triggiani et al., 2017), jak i narzędzie terapeutyczne w przypadku AD.

Drugim badaniem (Vincent-Lamarre et al., 2020) odnoszącym się do struktur hipokampu i orientacji przestrzennej oraz multitaskingu jest badanie z obszaru neuronauk obliczeniowych. Jednym z kroków efektywnego uczenia SRNN wzorców fal dźwiękowych w celu wyuczenia zdolności modulowania szybkością odtwarzanego słowa bez ponownego uczenia się jego szybszej/wolniejszej wersji jest nauka wzorców przestrzennych, takich jak koła i gwiazdy.

Podczas treningu włączano sygnały oscylacyjne, co skutkowało różnymi trajektoriami w zależności od względnej fazy oscylacji. W ten sposób sieć wykazywała odrębny wzorec aktywności dla każdego z dwóch zadań. Oglądane w dwóch wymiarach sygnały wyjściowe sieci szybko zbiegały się w okrąg i gwiazdę, które odpowiadały każdemu z dwóch kształtów celu, gdy dane wejściowe były podawane osobno. Kształty te były specyficzne dla określonej fazy wejścia oscylacyjnego – w warunkach, w których przedstawiliśmy sieci losowo wybraną konfigurację fazy, dane wyjściowe nie pasowały do żadnego z wytrenowanych wzorców.

Pełne wyniki eksperymentu sugerują, że duże sieci rekurencyjne mogą czerpać korzyści z autonomicznie generowanych sygnałów oscylacyjnych, aby uczyć się szerokiej gamy sztucznych i naturalistycznych sygnałów oraz wykazywać cechy aktywności neuronalnej, które są bardzo podobne do eksperymentów neurofizjologicznych.

PODSUMOWANIE

Potencjalny rozwój sztucznej inteligencji, opierający się na optymalizacji parametrów przy udziale wzmocnienia ze strony wzorców nienadzorowanego uczenia maszynowego, może zostać postrzegany jako wprost proporcjonalne przeciwieństwo globalnej degeneracyjnej desynchronizacji, która cechuje AD.

Analiza częstości aktywności mózgu, dostarczająca wzorców, zobrażeń i parametrów mogących stać się podstawą mapowania w uczeniu częściowo nadzorowanym, zdaje się potencjalnym narzędziem generowania wzorców, które posłużyć mogą rozwojowi sztucznej inteligencji. Hipoteza ta ściśle koresponduje z obecnymi badaniami z obszaru astrofizyki i aplikacji DL służącymi mapowaniu galaktyki wraz z wykorzystaniem analiz lagrangerowskich (Hong et al., 2021, Jeong et al., 2021, Quin, 2020).

Mówiąc o obszarze DL, warto jeszcze uwypuklić prawidłowość z badania oscylującego wokół teoretycznej analizy XRD opartej na krystalografii proszkowej, zwłaszcza z powodu połączenia z metaforycznym ujęciem XRD.

„XRD³⁴ może być uważana za analizę wzorców (np. fal mózgowych), które tworzą konstelacje, podobnie jak promienie słoneczne. A zatem analizy DL mogą zapewnić głęboki wgląd w ich sferę, a także w głębię ich parametrów wewnętrznych. Parametry te, jak i ich zbiory, zdają się nawiązywać do prawidłowości determinowania powstawania zobrazonej całości, nie tylko z poszczególnych elementów, lecz z sił i prawidłowości, które determinują te elementy. [...] W przeciwieństwie do takiego tradycyjnego podejścia opartego na prawach/aksjomatach, podejście głębokiego uczenia przyjmuje zupełnie inną zasadę. Wzór XRD jest uważany za nic innego jak jednowymiarowy obraz w podejściu głębokiego uczenia się, a głęboka konwolucyjna sieć neuronowa (CNN) jest wykorzystywana i wytrenowana w celu uczenia się podstawowych cech z dużej liczby wzorców XRD” (Lee et al., 2020).

Neuronalne i patofizjologiczne prawidłowości obecne w AD ściśle nawiązujące do charakterystycznej cechy rekursywności patologicznych agregacji, jak wykazało badanie

³ Rentgenowska dyfrakcja proszkowa (XRD) jest szybką techniką analityczną stosowaną głównie do identyfikacji faz materiału krystalicznego i może dostarczyć informacji o wymiarach komórek elementarnych. Analizowany materiał jest drobno zmielony, homogenizowany i określany jest średni skład nasypowy.

⁴ Dyfrakcja odnosi się do różnych zjawisk, które występują, gdy fala napotyka przeszkodę lub otwór. Definiuje się ją jako zagięcie fal wokół rogów przeszkody lub przez otwór w obszarze cienia geometrycznego przeszkody/otworu. Zauważyć można teoretyczne unaocnienie, zgodnie z którym całkowity konstrukt, będący wypadkową sumy poszczególnych elementów i wzorców je determinujących, zdaje się równolegle posiadać w sobie potencjał rozpadu na części pierwsze (i odwrotnie). A nawiązując do tej hipotezy, pokusić się można na odwołanie do choroby Alzheimera i sztucznej inteligencji, które obrazować może podobny mechanizm konstrukcji i dekonstrukcji na podstawie wzorców (analiz częstości lub poszczególnych wyładowań neuronalnych w obrębie dendrytów).

z listopada 2021 (Meisl et al., 2021), zdaje się znacząco korespondować z prawidłowościami analiz sygnału neuronalnego, które opierają się na aplikacji fraktalnego porządkowania sygnału neuronalnego, wykorzystującego między innymi ARIMA (*autoregressive integrated moving average*) bądź ARFIMA (*autoregressive fractionally integrated moving average*) (Tokhmpash et al., 2020).

BIBLIOGRAFIA

- Abbassian, H., Whalley, B.J., Sheibani, V., Shabani, M. (2016). Cannabinoid type 1 receptor antagonism ameliorates harmaline-induced essential tremor in rat: Cannabinoids and essential tremor. *British Journal of Pharmacology*, 173(22), 3196–3207.
- Adrian, E.D., Matthews, B.H.C. (1934). The interpretation of potential waves in the cortex. *The Journal of Physiology*, 81(4), 440–471.
- Aggrawal, C. (2018). *Neural Networks and Deep Learning*. Switzerland: Springer.
- Agnoli, S., Zanon, M., Mastroia, S., Avenanti, A., Corazza, G.E. (2020). Predicting response originality through brain activity: An analysis of changes in EEG alpha power during the generation of alternative ideas. *NeuroImage*, 207, 116385.
- Amini, M., Pedram, M.M., Moradi, A., Ouchani, M. (2021). Diagnosis of Alzheimer’s Disease by Time-Dependent Power Spectrum Descriptors and Convolutional Neural Network Using EEG Signal. *Computational and Mathematical Methods in Medicine*, 2, 1–17.
- Babiloni, C., Noce, G., Di Bonaventura, C., Lizio, R., Pascarelli, M.T., Tucci, F., Soricelli, A., Ferri, R., Nobili, F., Famà, F., Palma, E., Cifelli, P., Marizzoni, M., Stocchi, F., Frisoni, G.B., Del Percio, C. (2020). Abnormalities of Cortical Sources of Resting State Delta Electroencephalographic Rhythms Are Related to Epileptiform Activity in Patients with Amnesic Mild Cognitive Impairment Not Due to Alzheimer’s Disease. *Frontiers in Neurology*, 11, 514136.
- Baldwin, C.L., Roberts, D.M., Barragan, D., Lee, J.D., Lerner, N., Higgins, J.S. (2017). Detecting and Quantifying Mind Wandering during Simulated Driving. *Frontiers in Human Neuroscience*, 11, 406.
- Banhegyi, G., Baumeister, P., Benedetti, A., Dong, D., Fu, Y., Lee, A.S., Li, J., Mao, C., Margittai, E., Ni, M., Paschen, W., Piccirella, S., Senesi, S., Sitia, R., Wang, M., Yang, W. (2007). Endoplasmic Reticulum Stress. *Annals of the New York Academy of Sciences*, 1113(1), 58–71.
- Barthelson, K., Newman, M., Lardelli, M. (2021). Comparative analysis of Alzheimer’s disease knock-in model brain transcriptomes implies changes to energy metabolism as a causative pathogenic stress. *bioRxiv. Neuroscience* [praca niepublikowana].
- Benedek, M., Jauk, E., Sommer, M., Arendasy, M., Neubauer, A.C. (2014). *Intelligence, creativity, and cognitive control: The common and differential involvement of executive functions in intelligence and creativity*. *Intelligence*, 46, 73–83.
- Benedek, M., Könen, T., Neubauer, A.C. (2012). Associative abilities underlying creativity. *Psychology of Aesthetics, Creativity, and the Arts*, 6, 273–281.

- Berman, J.I., Liu, S., Bloy, L., Blaskey, L., Roberts, T.P.L., Edgar, J.C. (2015). Alpha-to-Gamma Phase-Amplitude Coupling Methods and Application to Autism Spectrum Disorder. *Brain Connectivity*, 5, 80–90.
- Calabrese, E.J., Rubio-Casillas, A. (2018). Biphasic effects of THC in memory and cognition. *European Journal of Clinical Investigation (EJCI)*, 48, 5, e12920, DOI: 10.1111/eci.12920.
- Cassani, R., Estarellas, M., San-Martin, R., Fraga, F.J., Falk, T.H. (2018). Systematic Review on Resting-State EEG for Alzheimer’s Disease Diagnosis and Progression Assessment. *Disease Markers*, 1–26, 5174815, DOI: 10.1155/2018/5174815.
- Cecchetti, G., Agosta, F., Basaia, S., Cividini, C., Cursi, M., Santangelo, R., Caso, F., Minicucci, F., Magnani, G., Filippi, M. (2021). Resting-state electroencephalographic biomarkers of Alzheimer’s disease. *NeuroImage: Clinical*, 31, 102711.
- Chaudhury, D., Liu, H., Han, M.-H. (2015). Neuronal correlates of depression. *Cellular and Molecular Life Sciences*, 72, 6, 4825–4848.
- Clay, F., Howett, D., FitzGerald, J., Fletcher, P., Chan, D., Price, A. (2020). Use of Immersive Virtual Reality in the Assessment and Treatment of Alzheimer’s Disease: A Systematic Review. *Journal of Alzheimer’s Disease*, 21, DOI: 10.3233/JAD-191218 .
- Compton, R.J., Gearing, D., Wild, H. (2019). The wandering mind oscillates: EEG alpha power is enhanced during moments of mind-wandering. *Cognitive, Affective, Behavioral Neuroscience*, 19, 5, 1184–1191.
- Corti, C., Poggi, G., Romaniello, R., Strazzer, S., Urgesi, C., Borgatti, R., Bardoni, A. (2018). Feasibility of a home-based computerized cognitive training for pediatric patients with congenital or acquired brain damage: An explorative study. *PLOS ONE*, 13(6), e0199001.
- Craik, A., He, Y., Contreras-Vidal, J.L. (2019). Deep learning for electroencephalogram (EEG) classification tasks: a review. *Journal of Neural Engineering*, 16, 031001.
- Cristino, L., Bisogno, T., Di Marzo, V. (2020). Cannabinoids and the expanded endocannabinoid system in neurological disorders. *Nature Reviews Neurology*, 16, 9–29.
- Cushman, L.A., Stein, K., Duffy, C.J. (2008). Detecting navigational deficits in cognitive aging and Alzheimer disease using virtual reality. *Neurology*, 71, 888–895.
- Del Rey, N.L.-G., Quiroga-Varela, A., Garbayo, E., Carballo-Carbajal, I., Fernández-Santiago, R., Monje, M.H.G., Trigo-Damas, I., Blanco-Prieto, M.J., Blesa, J. (2018). Advances in Parkinson’s Disease: 200 Years Later. *Frontiers in Neuroanatomy*, 12, 113, DOI: 10.3389/fnana.2018.00113.
- Deng, L. (2014). Deep Learning: Methods and Applications. *Foundations and Trends® in Signal Processing*, 7, 3–4, 197–387.
- Ebert, D.H., Greenberg, M.E. (2013). Activity-dependent neuronal signalling and autism spectrum disorder. *Nature*, 493, 327–337.
- Erguzel, T.T., Uyulan, C., Unsalver, B., Evrensel, A., Cebi, M., Noyan, C.O., Metin, B., Eryilmaz, G., Sayar, G. H., Tarhan, N. (2020). Entropy: A Promising EEG Biomarker Dichotomizing Subjects With Opioid Use Disorder and Healthy Controls. *Clinical EEG and Neuroscience*, 51(6), 373–381.
- Ferreira, C., Almeida, C., Tenreiro, S., Quintas, A. (2020). Neuroprotection or Neurotoxicity of Illicit Drugs on Parkinson’s Disease. *Life*, 10, 86, DOI: 10.3390/life10060086.

- Fink, A., Benedek, M. (2014). EEG alpha power and creative ideation. *Neuroscience & Biobehavioral Reviews*, 44, 111–123.
- Fowler, C.J. (2021). The endocannabinoid system – current implications for drug development. *Journal of Internal Medicine*, 290, 2–26.
- Gidon, A., Zolnik, T. A., Fidzinski, P., Bolduan, F., Papoutsi, A., Poirazi, P., Holtkamp, M., Vida, I., Larkum, M.E. (2020). Dendritic action potentials and computation in human layer 2/3 cortical neurons. *Science*, 367, 6473, 83–87.
- Gola, M., Magnuski, M., Szumska, I., Wróbel, A. (2013). EEG beta band activity is related to attention and attentional deficits in the visual performance of elderly subjects. *International Journal of Psychophysiology*, 89, 3, 334–341.
- Goodman, M.S., Kumar, S., Zomorodi, R., Ghazala, Z., Cheam, A.S.M., Barr, M.S., Daskalakis, Z.J., Blumberger, D.M., Fischer, C., Flint, A., Mah, L., Herrmann, N., Bowie, C.R., Mulsant, B.H., Rajji, T.K. (2018). Theta-Gamma Coupling and Working Memory in Alzheimer’s Dementia and Mild Cognitive Impairment. *Frontiers in Aging Neuroscience*, 10, 101.
- Grundman, M. (2004). Mild Cognitive Impairment Can Be Distinguished From Alzheimer Disease and Normal Aging for Clinical Trials. *Archives of Neurology*, 61, 59.
- Hata, M., Watanabe, Y., Tanaka, T., Awata, K., Miyazaki, Y., Fukuma, R., Taomoto, D., Satake, Y., Suehiro, T., Kanemoto, H., Yoshiyama, K., Iwase, M., Ikeda, S., Nishida, K., Takekita, Y., Yoshimura, M., Ishii, R., Kazui, H., Harada, T., Kishima, H., Ikeda, M., Yanagisawa, T. (2021). *Precise Discrimination for Multiple Underlying Pathologies of Dementia Cases Based on Deep-Learning with Electroencephalography* [praca niepublikowana].
- He, J.-T., Li, X.-Y., Yang, L., Zhao, X. (2020). Astroglial connexins and cognition: memory formation or deterioration? *Bioscience Reports*, 40, BSR20193510.
- Hinton, G.E. (2012). A Practical Guide to Training Restricted Boltzmann Machines. W: Montavon, G., Orr, G.B., Müller, K.-R. (eds.), *Neural Networks: Tricks of the Trade, Lecture Notes in Computer Science* (s. 599–619). Springer Berlin Heidelberg, Berlin, Heidelberg
- Hinton, G.E., Salakhutdinov, R.R. (2006). Reducing the Dimensionality of Data with Neural Networks. *Science*, 313, 504–507.
- Hong, S.E., Jeong, D., Hwang, H.S., Kim, J. (2021). Revealing the Local Cosmic Web from Galaxies by Deep Learning. *The Astrophysical Journal*, 913, 1, 76, DOI: 10.3847/1538-4357/abf040.
- Hubbard, N.A., Turner, M.P., Sitek, K.R., West, K.L., Kaczmarzyk, J.R., Himes, L., Thomas, B.P., Lu, H., Rypma, B. (2021). Resting cerebral oxygen metabolism exhibits archetypal network features. *Hum Brain Mapp*, 42, 1952–1968.
- Jensen, O., Mazaheri, A. (2010). Shaping Functional Architecture by Oscillatory Alpha Activity: Gating by Inhibition. *Frontiers in Human Neuroscience*, 4.
- Jha, D., Kim, J.-I., Kwon, G.-R. (2017). Diagnosis of Alzheimer’s Disease Using Dual-Tree Complex Wavelet Transform, PCA, and Feed-Forward Neural Network. *Journal of Healthcare Engineering*, 2017, 1–13, DOI: 10.1155/2017/9060124.
- Jeong, J. (2004). EEG dynamics in patients with Alzheimer’s disease. *Clinical Neurophysiology*, 115, 7, 1490–1505.
- Jin, C.Y., Borst, J.P. (2019). Predicting task-general mind-wandering with EEG. *Cognitive, Affective, & Behavioral Neuroscience*, 15.

- Kamiński, J., Sullivan, S., Chung, J.M., Ross, I.B., Mamelak, A.N., Rutishauser, U. (2017). Persistently active neurons in human medial frontal and medial temporal lobe support working memory. *Nature Neuroscience*, 20, 590–601.
- Kesner, A.J., Lovinger, D.M. (2020). Cannabinoids, Endocannabinoids and Sleep. *Frontiers in Molecular Neuroscience*, 13, 125.
- Kim, O., Pang, Y., Kim, J.-H. (2019). The effectiveness of virtual reality for people with mild cognitive impairment or dementia: a meta-analysis. *BMC Psychiatry*, 19, 219.
- Klimesch, W. (1999). EEG alpha and theta oscillations reflect cognitive and memory performance: A review and analysis. *Brain Research Reviews*, 29, 2–3, 169–195.
- Klimesch, W., Sauseng, P., Hanslmayr, S. (2007). EEG alpha oscillations: The inhibition–timing hypothesis. *Brain Research Reviews*, 53, 1, 63–88.
- Klimova, B., Maresova, P. (2017). Computer-Based Training Programs for Older People with Mild Cognitive Impairment and/or Dementia. *Frontiers in Human Neuroscience*, 11, 262.
- Köster, M., Finger, H., Graetz, S., Kater, M., Gruber, T. (2018). Theta-gamma coupling binds visual perceptual features in an associative memory task. *Scientific Reports*, 8, 17688.
- Kumar, S., Sharma, A., Tsunoda, T. (2019). Brain wave classification using long short-term memory network based OPTICAL predictor. *Scientific Reports*, 9, 9153.
- Laje, R., Buonomano, D.V. (2013). Robust timing and motor patterns by taming chaos in recurrent neural networks. *Nature Neuroscience*, 16, 925–933.
- Lee, J.-W., Park, W. B., Lee, J. H., Singh, S. P., Sohn, K.-S. (2020). A deep-learning technique for phase identification in multiphase inorganic compounds using synthetic XRD powder patterns. *Nature Communications*, 11, 1, 86.
- Lin, H., Jin, T., Chen, Lewen, Dai, Y., Jia, W., He, X., Yang, M., Li, J., Liang, S., Wu, J., Huang, J., Chen, Lidian, Liu, W., Tao, J. (2021). Longitudinal tracing of neurochemical metabolic disorders in working memory neural circuit and optogenetics modulation in rats with vascular cognitive impairment. *Brain Research Bulletin*, 170, 174–186.
- Lisman, J.E., Idiart, M.A.P. (1995). Storage of 7 ± 2 Short-Term Memories in Oscillatory Subcycles. *Science*, 267, 1512–1515.
- Lisman, J.E., Jensen, O. (2013). The Theta-Gamma Neural Code. *Neuron* 77, 1002–1016.
- Magosso, E., Crescenzo, F.D., Ricci, G., Piastra, S., Ursino, M. (2019). EEG Alpha Power is Modulated by Attentional Changes during Cognitive Tasks and Virtual Reality Immersion. *Computational Intelligence and Neuroscience*, 19, DOI: 10.1155/2019/7051079.
- Majoros, T., Ujvári, B., Oniga, S. (2019). EEG data processing with neural network. *Carpathian Journal of Electronic and Computer Engineering*, 12, 2, 33–36.
- Meisl, G., Hidari, E., Allinson, K., Rittman, T., DeVos, S.L., Sanchez, J.S., Xu, C.K., Duff, K.E., Johnson, K.A., Rowe, J.B., Hyman, B.T., Knowles, T.P.J., Klenerman, D. (2021). In vivo rate-determining steps of tau seed accumulation in Alzheimer’s disease. *Science Advances*, 7, 44, 1448.
- Minichino, A., Jackson, M.A., Francesconi, M., Steves, C.J., Menni, C., Burnet, P.W.J., Lennox, B.R. (2021). Endocannabinoid system mediates the association between gut-microbial diversity and anhedonia/amotivation in a general population cohort. *Molecular Psychiatry*, 26, 6269–6276.

- Mullins, R.F., Schoo, D.P., Sohn, E.H., Flamme-Wiese, M.J., Workamelahu, G., Johnston, R.M., Wang, K., Tucker, B.A., Stone, E.M. (2014). The Membrane Attack Complex in Aging Human Choriocapillaris. *The American Journal of Pathology*, 184, 3142–3153.
- Navamani, K. (2019). Extended Einstein diffusion-mobility equation for two-dimensional Schrödinger-type quantum materials. *Statistical Mechanics: Physical Sciences and Engineering*, 35.
- Noda, Y., Zomorodi, R., Saeki, T., Rajji, T.K., Blumberger, D.M., Daskalakis, Z.J., Nakamura, M. (2017). Resting-state EEG gamma power and theta–gamma coupling enhancement following high-frequency left dorsolateral prefrontal rTMS in patients with depression. *Clinical Neurophysiology*, 128, 3, 424–432.
- Palsson, S., Agustsson, E., Timofte, R., Van Gool, L. (2018). Generative Adversarial Style Transfer Networks for Face Aging. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2165–21658.
- Parish, G., Hanslmayr, S., Bowman, H. (2018). The Sync/deSync Model: How a Synchronized Hippocampus and a Desynchronized Neocortex Code Memories. *Journal of Neuroscience*, 38, 3428–3440.
- Parr, T., Limanowski, J., Rawji, V., Friston, K. (2021). The computational neurology of movement under active inference. *Brain*, 144, 1799–1818.
- Perez, J.D., Rubinstein, N.D., Fernandez, D.E., Santoro, S.W., Needleman, L.A., Ho-Shing, O., Choi, J.J., Zirlinger, M., Chen, S.-K., Liu, J.S., Dulac, C. (2015). Quantitative and functional interrogation of parent-of-origin allelic expression biases in the brain. *eLife*, 4, e07860.
- Petersen, R.C. (2004). Mild cognitive impairment as a diagnostic entity. *Journal of Neuroscience*, 256, 183–194.
- Quin, H. (2020). Machine learning and serving of discrete field theories. *Scientific Reports*, 10, 19329.
- Radford, A., Metz, L., Chintala, S. (2016). *Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks*. arXiv:1511.06434.
- Radivojević, T., Costello, Z., Workman, K., Garcia Martin, H. (2020). A machine learning Automated Recommendation Tool for synthetic biology. *Nature Communications*, 11, 1, 4879.
- Rangayyan, R.M. (2002). *Biomedical Signal Analysis*, New York, USA: *IEEE press in Biomedical Engineering*.
- Robison, A.J., Nestler, E.J. (2011). Transcriptional and epigenetic mechanisms of addiction. *Nature Reviews Neuroscience*, 12, 623–637.
- Romei, V., Gross, J., Thut, G. (2010). On the Role of Prestimulus Alpha Rhythms over Occipito-Parietal Areas in Visual Input Regulation: Correlation or Causation? *Journal of Neuroscience*, 30, 8692–8697.
- Roy, Y., Banville, H., Albuquerque, I., Gramfort, A., Falk, T.H., Faubert, J., 2019. Deep learning-based electroencephalography analysis: a systematic review. *Journal of Neural Engineering*, 16, 051001.
- Russo, S.J., Dietz, D.M., Dumitriu, D., Morrison, J.H., Malenka, R.C., Nestler, E.J. (2010). The addicted synapse: mechanisms of synaptic and structural plasticity in nucleus accumbens. *Trends in Neurosciences*, 33, 267–276.

- Salomon, F.D.R., Marisa, S.G., Nathaly, M.A.P. (2020). *Study of Artificial Intelligence Models Applied to the Analysis of Electroencephalograms in Alzheimer's Disease*. Universidad De Investigación De Tecnología Experimental Yachay Escuela de Ciencias Matemáticas y Computacionales. Pobrano z: <http://repositorio.yachaytech.edu.ec/handle/123456789/123> [10.11.2021].
- Sangaiah, A. (ed.) (2019). *Deep Learning and Parallel Computing Environment for Bioengineering Systems*. Elsevier.
- Santoro, A., Mele, E., Marino, M., Viggiano, A., Nori, S.L., Meccariello, R. (2021). The Complex Interplay between Endocannabinoid System and the Estrogen System in Central Nervous System and Periphery. *International Journal of Molecular Sciences*, 22, 972.
- Sauseng, P., Klimesch, W., Gerloff, C., Hummel, F.C. (2009). Spontaneous locally restricted EEG alpha activity determines cortical excitability in the motor cortex. *Neuropsychologia*, 47, 284–288.
- Sauseng, P., Klimesch, W., Heise, K.F., Gruber, W.R., Holz, E., Karim, A.A., Glennon, M., Gerloff, C., Birbaumer, N., Hummel, F.C. (2009). Brain Oscillatory Substrates of Visual Short-Term Memory Capacity. *Current Biology*, 19, 1846–1852.
- Seo, J., Laine, T.H., Oh, G., Sohn, K.-A. (2020). EEG-Based Emotion Classification for Alzheimer's Disease Patients Using Conventional Machine Learning and Recurrent Neural Network Models. *Sensors*, 20, 7212.
- Smallwood, J., Schooler, J.W. (2015). The Science of Mind Wandering: Empirically Navigating the Stream of Consciousness. *Annual Review of Psychology*, 66, 1, 487–518.
- Stern, J.M., Engel, J. (2013). *Atlas of EEG patterns*. Wolters Kluwer – Lippincott Williams & Wilkins.
- Stretton, J., Thompson, P.J. (2012). Frontal lobe function in temporal lobe epilepsy. *Epilepsy Research*, 98, 1, 1–13.
- Tamura, M., Spellman, T.J., Rosen, A.M., Gogos, J.A., Gordon, J.A. (2017). Hippocampal-prefrontal theta-gamma coupling during performance of a spatial working memory task. *Nature Communications*, 8, 2182.
- Tanveer, M., Richhariya, B., Khan, R.U., Rashid, A.H., Khanna, P., Prasad, M., Lin, C.T. (2020). Machine Learning Techniques for the Diagnosis of Alzheimer's Disease: A Review. *ACM Transactions on Multimedia Computing, Communications, and Applications*, 16.
- Tokhmpash, A., Hadipour, S., Shafai, B. (2020). On Analysis of Fractional Order System Identification. *2020 IEEE Conference on Control Technology and Applications (CCTA)*, 237–241.
- Tirozzi, B., Londei, F., Gianani, S. (2020). Depolarization Block in the Endocannabinoid System of the Hippocampus. *Journal of Neuroscience*, 1, 85–97, DOI: 10.3390/neurosci1020008.
- Triggiani, A.I., Bevilacqua, V., Brunetti, A., Lizio, R., Tattoli, G., Cassano, F., Soricelli, A., Ferri, R., Nobili, F., Gesualdo, L., Barulli, M.R., Tortelli, R., Cardinali, V., Giannini, A., Spagnolo, P., Armenise, S., Stocchi, F., Buenza, G., Scianatico, G., Logroscino, G., Lacidogna, G., Orzi, F., Buttinelli, C., Giubilei, F., Del Percio, C., Frisoni, G.B., Babiloni, C. (2017). Classification of Healthy Subjects and Alzheimer's Disease Patients with Dementia from Cortical Sources of Resting State EEG Rhythms: A Study Using Artificial Neural Networks. *Frontiers in Human Neuroscience*, 10, DOI: 10.3389/fnins.2016.00604.

- Thut, G. (2006). Band Electroencephalographic Activity over Occipital Cortex Indexes Visuospatial Attention Bias and Predicts Visual Target Detection. *Journal of Neuroscience*, 26(37), 9494–9502.
- Upadhyaya, V., Sastry, P.S. (2019). An Overview of Restricted Boltzmann Machines. *Journal of the Indian Institute of Science*, 99, 225–236.
- Urban, N., Guillemot, F. (2014). Neurogenesis in the embryonic and adult brain: same regulators, different roles. *Frontiers in Cellular Neuroscience*, 8.
- Vahid, A., Mückschel, M., Stober, S., Stock, A.-K., Beste, C. (2020). Applying deep learning to single-trial EEG data provides evidence for complementary theories on action control. *Communications Biology*, 3, 112.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, Ł., Polosukhin, I. (2017). Attention is All you Need. W: I. Guyon, U.V. Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, R. Garnett (eds.), *Advances in Neural Information Processing Systems*. Vol. 30. Curran Associates, Inc.
- Venkatesh, H.S., Morishita, W., Geraghty, A.C., Silverbush, D., Gillespie, S.M., Arzt, M., Tam, L.T., Espenel, C., Ponnuswami, A., Ni, L., Woo, P.J., Taylor, K.R., Agarwal, A., Regev, A., Brang, D., Vogel, H., Hervey-Jumper, S., Bergles, D.E., Suvà, M.L., Malenka, R.C., Monje, M. (2019). Electrical and synaptic integration of glioma into neural circuits. *Nature*, 573, 539–545.
- Vincent-Lamarre, P., Calderini, M., Thivierge, J.-P. (2020). Learning Long Temporal Sequences in Spiking Networks by Multiplexing Neural Oscillations. *Frontiers in Computational Neuroscience*, 14, 78.
- Yang, L., Chen, Z., Li, J., Ding, P., Wang, Y. (2021). Effects of Escitalopram on Endoplasmic Reticulum Stress and Oxidative Stress Induced by Tunicamycin. *Frontiers in Human Neuroscience*, 15, 737509.
- YaoChong, L., Ri-Gui, R., RuiQing, X., Wen Wen, H., Ping, F. (2021). Quantum algorithm for the nonlinear dimensionality reduction with arbitrary kernel. *Quantum Science and Technology*, 6, 1, 6 014001.
- Zahra, A., Kanwal, N., Ur Rehman, N., Ehsan, S., McDonald-Maier, K.D. (2017). Seizure detection from EEG signals using Multivariate Empirical Mode Decomposition. *Computers in Biology and Medicine*, 88, 132–141.
- Zani, A., Tumminelli, C., Proverbio, A.M. (2020). Electroencephalogram (EEG) Alpha Power as a Marker of Visuospatial Attention Orienting and Suppression in Normoxia and Hypoxia. An Exploratory Study. *Brain Sciences*, 10, 3, 140.
- Zedelius, C.M., Broadway, J.M., Schooler, J.W. (2015). Motivating meta-awareness of mind wandering: A way to catch the mind in flight? *Consciousness and Cognition*, 36, 44–53.
- Zeiler, M.D., Fergus, R. (2014). Visualizing and Understanding Convolutional Networks, in: Fleet, D., Pajdla, T., Schiele, B., Tuytelaars, T. (eds.), *Computer Vision – ECCV 2014, Lecture Notes in Computer Science*. Springer International Publishing, 818–833.
- Zhang, H., Watrous, A.J., Patel, A., Jacobs, J. (2018). Theta and Alpha Oscillations Are Traveling Waves in the Human Neocortex. *Neuron*, 98, 1269–1281.e4.

ALZHEIMER'S DISEASE AS AN EXAMPLE OF DESYNCHRONIZATION OF FUNCTIONING
AND A SET OF NEUROCOGNITIVE PATTERNS CONSTITUTING A POTENTIAL SOURCE OF
RESOURCES FOR THE DEVELOPMENT OF ARTIFICIAL INTELLIGENCE

The review article focuses on the potential development of Artificial Intelligence by extracting fixed patterns and regularities that enable the improvement and refinement of advanced analyses in the field of artificial neural network learning. It is conducted through the prism of the neurocognitive view of Alzheimer's disease as a potential set of neurocognitive patterns constituting a potential source of resources for the development of artificial intelligence. It is closely related to encephalography, both used to detect pathological dementia changes, and the analysis of brain activity itself, showing the existence of repeated regularities. These patterns, analogic in the astrophysical Lagrangian mapping analysis of the galaxy, seem to have the potential to develop Artificial Intelligence. Especially, following the idea of perceiving Alzheimer's disease as a global functional desynchronisation, global neurodegenerative changes may provide potential resources that, through mathematical and algebraic transformations, to serve as a foundation for the development of Artificial Intelligence.

Keywords: Alzheimer's disease, EEG, artificial intelligence, deep learning, brain waves

Zgłoszenie artykułu: 14.11.2021

Recenzje: 8.01.2022

Rewizja: 15.01.2022

Akceptacja: 17.01.2022

Publikacja online: 31.03.2022