

## *Memrystywny układy neuromimetyczne i rezerwuarowe*

Opracowywanie materiałów półprzewodnikowych i badanie mechanizmów ich działania pozwoliło na stworzenie i rozwój technologii komputerowych stanowiących fundament cywilizacji informacji, z którą mamy do czynienia w dzisiejszych czasach. Analiza i przetwarzanie danych w domenach usług internetowych, finansów, autonomicznych pojazdów czy inteligentnej infrastruktury bazującej na urządzeniach Internetu Rzeczy jest wykonywane z wykorzystaniem narzędzi *uczenia maszynowego* (obok klasycznych metod statystycznych). Jedną z intensywnie rozwijanych gałęzi uczenia maszynowego są *sztuczne sieci neuronowe*. W swojej funkcjonalności i/lub strukturze wzorują się one na biologicznych układach nerwowych. Wynika to z ogromnych zdolności mózgu do uczenia się, rozpoznawania wzorców oraz ich klasyfikacji. Jego zdolności bazują głównie na wysoce równoległym i iteracyjnie zoptymalizowanym przetwarzaniu danych w oparciu o wielką liczbę połączonych ze sobą neuronów.

W ramach prób poprawy wydajności urządzeń komputerowych, prowadzone są intensywne badania z zastosowaniem *inżynierii neuromorficznej*. Ta interdyscyplinarna dziedzina, w której głównym wzorcem układów obliczeniowych są biologiczne struktury nerwowe, czerpie inspiracje z matematyki, elektroniki, inżynierii materiałowej, biologii i informatyki. Wykorzystanie nowoczesnych technologii materiałowych umożliwia symulowanie neuronalnych oraz synaptycznych funkcji o różnych stopniach złożoności, co w efekcie zapewnia zwiększoną równoległość działania w obszarach takich jak rozpoznawanie wzorców i analiza grafów. Obecnie zagadnienia związane z inżynierią neuromorficzną znajdują się w dziedzinie niekonwencjonalnego przetwarzania informacji, lecz ten fakt powoli się zmienia. Wiele jednostek naukowych prowadzi intensywne badania czerpiące inspiracje z biologicznych struktur nerwowych w celu osiągnięcia wydajniejszych układów obliczeniowych, potencjalnie o uniwersalnym charakterze.

Jedną z innowacyjnych technologii z domeny inżynierii neuromorficznej są urządzenia *memrystywny*. Wykorzystanie urządzeń memrystywnych pozwala delegować niektóre etapy obliczeniowe sztucznych sieci neuronowych tak, aby były wykonane *in materia*, bazując wprost na właściwościach danego urządzenia. Takie podejście wydaje się omijać problem „wąskiego gardła von Neumanna”. W klasycznych systemach obliczeniowych informacje są przechowywane w pamięci, a wszystkie obliczenia wykonywane są w mikroprocesorze. Architektura von Neumanna zakłada stały przepływ danych pomiędzy tymi komponentami komputera, co w efekcie spowalnia obliczenia i zużywa energię. Systemy dynamiczne (zarówno półprzewodnikowe, jak i układy „mokre” (ang. *wetware*)) umożliwiają przeprowadzanie obliczeń również w układach posiadających funkcje pamięci.

W klasycznej konfiguracji urządzeń memrystywnych, materiał pojemnościowy (np. dielektryk lub półprzewodnik) umieszczany jest pomiędzy elektrodami o przewodnictwie metalicznym w układzie warstwowym. Urządzenia memrystywny cechują się nieliniową charakterystyką prądowo-napięciową, która przyjmuje formę pętli histerezy. Dla klasycznych urządzeń memrystywnych można zaobserwować dwa stany oporności (niskiej oraz wysokiej). Poprzez zastosowanie impulsów elektrycznych lub przebiegów zmiennonapięciowych o odpowiedniej amplitudzie potencjału elektrycznego, materiały można przełączać do odpowiednich stanów przewodnictwa w zależności od typu memrystora i jego stanu początkowego. Zmienność działania w zależności od częstotliwości impulsów/skanów wzbudzających jest kolejną cechą

urządzeń memrystywnych. Ze względu na retencję stanów obserwowaną dla elementów memrystywnych po wyłączeniu źródła zasilania, efekt przełączania rezystywnego może zostać wykorzystany jako element konstrukcyjny nowej pamięci nieulotnej.

Jednym z problemów sztucznych sieci neuronowych jest ich kosztowny proces uczenia, szczególnie w przypadku rekurencyjnych bądź głębokich sieci neuronowych. Optymalizacji podlegają wszystkie wagi połączeń pomiędzy poszczególnymi neuronami, jak również sam poziom aktywacji danego neuronu. Gdy sieć zawiera rekurencyjne połączenia bądź wiele warstw, każda iteracja aktualizacji wag wydłuża trenowanie całej sieci. Aby rozwiązać ten problem, Jaeger oraz Maas niezależnie zaproponowali odpowiednio *Echo State Network* oraz *Liquid State Machine*. W ich podejściu, trenowaniu podlega jedynie fragment sieci próbujący stan warstwy przetwarzającej informacje. W swoich pracach wskazali na kluczowe znaczenie wielowymiarowej, bogatej oraz dynamicznej przestrzeni stanów warstwy przetwarzającej informacje. Z czasem, oba z tych podejść efektywnego trenowania sieci neuronowych zostały ujęte we wspólne ramy koncepcyjne, które określono jako *obliczanie rezerwuarowe*.

Aby poprawnie działać, te niekonwencjonalne systemy obliczeniowe muszą posiadać kilka cech, a mianowicie muszą wykazywać bogatą dynamikę wewnętrzną, pamięć „ulotną” oraz właściwość *echa stanów*. Obwody obliczania rezerwuarowego są oparte na: (i) elemencie nieliniowym (np. memrystorze), który zapewnia również funkcje pamięci, (ii) warstwie wejściowej, która dostarcza informacje/sygnal do przetwarzania, (iii) warstwie odczytu i opcjonalnie (iv) opóźnionej pętli sprzężenia zwrotnego, która uzupełnia i rozwija wewnętrzną dynamikę systemu. Do odczytu stanu warstwy rezerwuaru nie jest potrzebna wyrafinowana sztuczna sieć neuronowa, lecz wystarczą proste modele, takie jak regresja liniowa czy drzewo binarne (zakładając że układ rezerwuarowy dokonuje odpowiedniej transformacji sygnału).

*Single Node Echo-State Machine* (SNESM) to nowatorskie systemy obliczania rezerwuarowego, które wykorzystują tylko jeden węzeł obliczeniowy działający w pętli opóźnionego sprzężenia zwrotnego. Zasadniczo zarówno sygnał, jak i stan węzła obliczeniowego zmieniają się za każdym razem, gdy sygnał przechodzi przez urządzenie w każdym kolejnym cyklu. Ewolucja sygnału w pętli może potencjalnie poprawić możliwości grupowania i klasyfikacji systemu obliczania rezerwuarowego. System SNESM daje dodatkową korzyść w postaci rozszerzenia zestawu danych wejściowych. Każda kolejna epoka sygnału jest nieco inną wersją sygnału bazowego ze względu na nieliniową transformację i tłumienie

w układzie SNESM. Echo sygnału pierwotnego może być łatwiejsze do sklasyfikowania ze względu na zmiany w jego złożoności i korelacji pomiędzy opisującymi je parametrami.

W ramach pracy doktorskiej „Memrystywne układy neuromimetyczne i rezerwuarowe” wykonane zostały badania nad wykorzystaniem kilku substratów obliczeniowych w domenie niekonwencjonalnego przetwarzania informacji. Wykonane prace uporządkowano tak, aby wprowadzać kolejne elementy i koncepcje zarówno konstrukcji układu, jak i sposobów przetwarzania informacji i jej analizy, które finalnie są zsyntezowane w pojedynczych badaniach.

W pierwszej kolejności przedstawiono artykuł przeglądowy w którym zawarty jest opis memfraktorów (model uwzględniający urządzenia memrystywne), prostych algorytmów sztucznych sieci neuronowych oraz układów obliczania rezerwuarowego. Zawarto również matematyczny opis układów rezerwuarowych z pętlą sprzężenia zwrotnego.

Następnie przedstawiono badania nad fotoelektrochemicznym sztucznym neuronem, które wskazują na możliwość wykorzystania prostego układu neuromorficznego do zadania klasyfikacji pisma odręcznego. Pomiary zrealizowano na bazie polimorficznego siarczku kadmu, przedstawiono również jego charakterystykę spektroskopową. Wyniki wskazują na poprawę w separowalności danych wejściowych przetworzonych przez układ neuromorficzny względem surowych danych. Praca wprowadza koncepcje konstrukcji układu przetwarzającego informacje przy wykorzystaniu pojedynczego węzła obliczeniowego. Wprowadzono również elementy analizy danych.

Paradygmat obliczeniowy rezerwurowego obliczania wprowadzony jest wprost w badaniach bazujących na układzie zawierającym cement domieszkowany nanomateriałami półprzewodnikowymi oraz drobinami metalicznymi. Właściwości elektryczne wybranych próbek zostały zbadane za pomocą woltamperometrii cyklicznej oraz spektroskopii impedancyjnej. Prezentowany układ został wykorzystany do klasyfikacji sygnałów elektrycznych o prostych kształtach – sinusoidalny, trójkątny oraz prostokątny. Dodatkowo, jeden z parametrów złożoności analizowanych sygnałów umożliwia rozróżnienie pomiędzy domieszkowaniem próbki. Badania podtrzymują i uzupełniają doniesienia literaturowe o możliwości realizacji obliczania rezerwurowego na najprostszych substratach obliczeniowych przeznaczonych do zadań klasyfikacyjnych.

Możliwość wykorzystania pojedynczego węzła obliczeniowego w rezerwurowym układzie z pętlą sprzężenia zwrotnego (SNESM) przedstawiono na bazie polimerowego tranzystora polowego. Prezentowany układ SNESM jest bardzo bliski koncepcyjnie do algorytmu *State Weaving Environment Echo Tracker*, w którym układ rezerwurowy jest w bezpośrednim kontakcie z analizowanym środowiskiem. Badany układ wykorzystano do poprawy działania tranzystora polimerowego w roli prostego sensora jonów. Dokonano tego poprzez zmianę reprezentacji danych, możliwą dzięki transformacji (zależnej od stężenia analizowanych jonów  $K^+$ ) sygnału w układzie SNESM.

Badania nad wykorzystaniem rezerwurowego układu SNESM do analizy i grupowania interwałów muzycznych zrealizowano na bazie symulacji *synapsy mostkowej*. Synapsa mostkowa składa się z czterech memrystorów oraz wzmacniacza operacyjnego. W ramach badań przedstawiono generacje wyższych harmonicznych w kilku układach memrystywnych. Przedstawiono porównanie efektów transformacji sygnałów sinusoidalnych reprezentujących interwały muzyczne w skali naturalnej z krzywą konsonansów/dysonansów sensorycznych oraz wyznaczonych na podstawie algorytmu Setharesa. Reprezentacja danych w przestrzeni odległości składowych harmonicznych umożliwia częściowe grupowanie interwałów muzycznych względem ich stopnia konsonansu/dysonansu.

Finalnie, prezentowane są badania nad fizyczną implementacją synapsy mostkowej na bazie pół-komercyjnych memrystorów KNOWM w układzie rezerwurowym SNESM w celu rozpoznania ataku epilepsji. W badaniach tych do trenowania modelu wykorzystano prosty algorytm uczenia maszynowego – drzewo binarne. Analizowany, pobrany online standardowy zestaw danych został zebrany z wykorzystaniem trójosiowego akcelerometru noszonego na rękę dla prostej diagnostyki ataku epilepsji bez konieczności stosowania systemu EEG. W ramach *cech* wykorzystywanych do szkolenia modelu zastosowano szereg parametrów określających złożoność analizowanych sygnałów. Obliczenia parametrów złożoności wykonano również dla nieprzetworzonych danych aby porównać wpływ układu SNESM na

dany sygnał oraz jakość jego klasyfikacji. Do oceny dokładności klasyfikacji wykorzystano F1-score – zbalansowany parametr statystyczny lepiej oddający zdolność do klasyfikacji układu niż prosta *precyzja*. Przedstawiono wyniki poprawy dokładności klasyfikacji sygnałów symulujących atak epilepsji dla restrykcyjnych warunków (niewielkie zestawy danych) gdzie istotna jest szybkość i prostota – co tym samym wpływa na niski koszt – trenowania i testowania finalnego modelu klasyfikacyjnego. Źródłem poprawy klasyfikacji mogą być zmiany w dystrybucjach analizowanych parametrów oraz zmiany w korelacji pomiędzy nimi. Dodatkowo korzystny wpływ ma zdolność do ekspansji zestawu danych przez układ SNESM.