

Antykruche systemy sterowania w przetwarzaniu neuronalnym: perspektywa sensomotoryczna

By kama3 kama3

paź 8, 2025

Kontinuum stabilności – wytrzymałości – odporności – adaptacyjności w przetwarzaniu neuronalnym podąża za strukturą hierarchiczną, która wyjaśnia interakcje i przetwarzanie informacji w różnych skalach czasowych.

Co ciekawe, wykorzystując „kanoniczne” neuronowe obwody obliczeniowe, takie jak regulacja aktywności homeostatycznej (Homeostatic Activity Regulation), zasada „zwycięzca bierze wszystko” (Winner-Take-All) i hebbiowskie uczenie się korelacji czasowej (Temporal Correlation Learning), można rozszerzyć spektrum zachowań w kierunku antykruchości.

Antykruchość, obecna zarówno w teorii prawdopodobieństwa, jak i w układach dynamicznych, może wyjaśniać i definiować interesujące wzajemne oddziaływanie obwodów neuronowych, występujące na przykład w kontroli sensomotorycznej w warunkach niepewności i zmienności. Ta perspektywa proponuje nowe ramy do analizy i opisu przetwarzania neuronalnego w pętli zamkniętej z wykorzystaniem zasad antykruchości, ukierunkowanych na kontrolę sensomotoryczną. Nasz cel jest dwojaki. Po pierwsze, wprowadzamy kontrolę antykruchą jako ramy koncepcyjne do kwantyfikacji zachowań sieci neuronowych w pętli zamkniętej, które czerpią korzyści z niepewności i zmienności. Po drugie, wprowadzamy zasady projektowania sieci neuronowych, otwierając drogę do implementacji neuromorficznych i przeniesienia ich do systemów technicznych.

Teoria sterowania ze sprzężeniem zwrotnym oferuje najbardziej wszechstronny i kompleksowy zestaw metodologii analizy i syntezy dla systemów dynamicznych o zadanej dynamice. W systemach technicznych ramy te są ucieleśniane jako skonstruowana maszynaria, która przekształca jakościowe wyjaśnienia mechanistyczne w środki osiągania zadanej dynamiki w obecności...niepewność i zmienność W przeciwieństwie do tego w układach biologicznych, teoria sterowania sprzężeniem zwrotnym jest wykorzystywany w sposób inżynierii wstecznej poprzez generowanie hipotez jakościowych i przechwytywanie mechanizmów, które utrzymują funkcję pod wpływem dynamika nieliniowa i nieprzewidziane zaburzenia.

Przetwarzanie neuronowe oferuje złożony i subtelny system kanoniczny, który ujawnia szeroki repertuar dynamiki. Pod wpływem zaburzeń, które mogą występować w skalach czasowych od milisekund do miesięcy, a nawet lat, sieci neuronowe muszą zachować stabilność. Wydaje się to paradoksalne, ale jedynym sposobem na utrzymanie stabilności sieci neuronowych jest ich pobudliwość, zdolność do adaptacji swojej odpowiedzi (i struktury) w reakcji na bodźce zewnętrzne oraz zdolność do odpowiedniego reagowania. Perspektywę tę wspiera również teoria Towera o selektywnie korzystnej niestabilności (Selectively Advantageous Instability, Tower 2024) oraz wariacyjna i relacyjna stabilność systemów odpornych (Resilient Resilient) Bettingera i Fristona (2023). Co ciekawe, praca SAI bada minimalny zestaw modeli, które mogą definiować korzyści z niepewności na wielu poziomach organizacji biologicznej poprzez „selektywnie korzystną niestabilność”.

Złożone mechanizmy leżące u podstaw zachowania funkcjonalności biologicznej niezmiennie pociągają za sobą zaangażowanie licznych procesów w wielowymiarowej przestrzeni parametrów. Ta inherentna złożoność sprawia, że powrót systemu biologicznego do stanu pierwotnego jest praktycznie niemożliwy. W związku z tym termin „stabilność” jest pomijany w kontekście opisu utrzymania struktur i funkcji biologicznych. Termin ten jest jednak używany do scharakteryzowania zachowania systemu.

Rozważając przetwarzanie neuronalne, stabilność układu dynamicznego określamy jako tendencję do powrotu do początkowych, ustalonych, zrównoważonych relacji między działającymi w nim komponentami (tj. okresu refrakcji po impulsie i repolaryzacji komórek) po wyeliminowaniu zakłócenia wejściowego. Definicja ta jest zgodna z ramami Miller & Albarracín, 2022 Miller et al. (2022), gdzie stabilność jest postrzegana przez pryzmat trzech niuansów odporności, a mianowicie bezwładności, elastyczności i plastyczności. Rozwijając spektrum, definiujemy niniejszym odporność jako zdolność układu do przetrwania zakłóceń lub zmian w jego wejściu. Ściśle powiązane, odporność definiujemy jako zdolność układu do odzyskania równowagi po wystąpieniu różnorodnych zmian parametrów. W tym przypadku, pomimo tych modyfikacji, układ reaguje, modyfikując swoje stany wewnętrzne, aby zachować swoją ogólną funkcję. Rozważmy na przykład pobudliwość pojedynczych neuronów lub sieci neuronowych, które mogą wytrzymać zmiany ekspresji kanałów jonowych, częstotliwości stymulacji, temperatury, zasolenia i pH. Neurony są plastyczne i zdolne do adaptacji swojego zachowania w obliczu nowego zadania, tj. zmiany wzorca wejściowego dotyczącego ich charakterystyki częstotliwościowo-prądowej. Opisuje to kolejne zachowanie w spektrum, a mianowicie adaptację. To zachowanie definiuje się jako zbiór natychmiastowych dostosowań w komórce lub systemie (tj. sieci neuronowej) wyzwalanych przez ciągłą obecność bodźca.

Niniejszym proponujemy rozważenie antykruchości jako nowego elementu spektrum zachowań przetwarzania neuronowego, wykraczającego poza solidność, odporność i adaptację. Pokazujemy, jak wykorzystuje ona wielowymiarowość, w której rozwija się przetwarzanie neuronowe, aby uchwycić, jak pojedyncze neurony i sieci neuronowe nie tylko absorbują i reagują na zmiany, ale także czerpią korzyści z niestabilnych zakłóceń i niepewności. Przedstawiamy nową perspektywę na to, jak pojedyncza komórka, w obrębie sieci neuronowych i pomiędzy nimi, działa w zamkniętej pętli, budując zdolność do przewidywania zmian w ich danych wejściowych, a tym samym do czerpania korzyści z nieodłącznej niepewności.

Antykruchość to nieliniowa, wypukła odpowiedź, którą system wykazuje w obliczu zmienności na dobrze zdefiniowaną funkcję wypłaty. Opiera się to na założeniu, że antykruchość jest lokalnym atrybutem systemu dynamicznego w określonym obszarze jego przestrzeni wejściowej. System może stać się podatny na zakłócenia, jeśli jego trajektoria wykroczy poza ten zakres. Ze względu na swoją nieliniową reakcję system jest nie tylko odporny na wstrząsy, ale także antykruchy, co oznacza, że może nawet na nich skorzystać. Według Axenie i in. (2024) antykruchość przejawia się w różnych skalach czasowych, od krótkich interakcji lokalnych (tj. wewnętrznej antykruchości), przez krótkozasięgowe interakcje modulacyjne (tj. odziedziczoną antykruchość), aż po sterowanie zachowaniami w zamkniętej pętli (tj. indukowaną antykruchość).

1.2.1 Wewnętrzna antykruchość

Wewnętrzna antykruchość (lub kruchość) jest definiowana jako korzyść (lub szkoda) wynikająca z rozkładu danych wejściowych, nierównomierności, zmienności lub zaburzeń przypisywanych nieliniowości funkcji wypłaty systemu. Należy zauważyć ścisły związek tego zjawiska z nierównością Jensena, która głosi, że wartość oczekiwana zmiennej losowej niekoniecznie jest równa jej wartości średniej:

Odziedziczona antykruchość (lub kruchość) jest definiowana jako kwantyfikacja korzyści (lub szkody) wynikającej z nierównomierności rozkładu danych wejściowych, zmienności lub zaburzeń przypisywanych reakcji systemu na sygnały zewnętrzne. W wielu scenariuszach funkcja wypłaty systemu może być nieznana (lub niemierzalna) lub może być znana, ale sygnały zewnętrzne wprowadzają dodatkowe nieliniowości.

Koncepcja indukowanej/interwencyjnej antykruchości (lub kruchości) obejmuje kwantyfikację korzyści (lub szkód) związanych z nierównomiernością rozkładu danych wejściowych, ich zmiennością lub zaburzeniami. Zjawiska te przypisuje się reakcji systemu na dynamikę pętli zamkniętej, która jest napędzana przez kombinację różnych mierzalnych wielkości i z góry określonych trajektorii systemu. Ten rodzaj antykruchości

opiera się na połączeniu separacji skal czasowych, redundantnej nadkompensacji i sterowania w pętli zamkniętej o zmiennej strukturze, które narzuca z góry określoną dynamikę w warunkach niepewności. Zajmiemy się tym później w tekście, opisując przetwarzanie między populacjami neuronów.

Istnieje wartość dodana w połączeniu bardzo solidnej bazy wiedzy w dziedzinie neuronauki i obliczeniowej neuronauki z podejściami inżynierskimi w celu „wydobycia” nowych „przepisów” projektowych, które wprowadzą zasady przetwarzania neuronowego do sprzętowych i programowych wystąpień neuromorficznych, takich jak Neuromorphic Intermediate Representations (NIR) Pedersen i in. (2023). NIR to inicjatywa oprogramowania typu open source, która proponuje wspólne ramy odniesienia dla obliczeń w cyfrowych systemach neuromorficznych.

Kluczową zaletą NIR i potencjałem w zakresie tworzenia neuronowych projektów antykruchych jest możliwość oddzielenia rozwoju sprzętu i oprogramowania neuromorficznego od rozwoju modelu i algorytmów. Ułatwia to interoperacyjność między platformami i zwiększa dostępność wielu technologii neuromorficznych.

Rozwijając tę ideę, zmienność zdefiniowano jako nieliniową kombinację początku, czasu trwania i amplitudy zakłócenia sygnału zewnętrznego.

Jak ujęto w pracach Taleba (2012), Taleba i Douady'ego (2013), skłonność systemu dynamicznego do czerpania korzyści z nieprzewidywalności, zmienności i niepewności, w przeciwieństwie do kruchości, jest definiowana jako antykruchosc. Reakcja antykruchego systemu dynamicznego na zaburzenia wykracza poza solidność i odporność, do tego stopnia, że czynniki stresogenne mogą poprawić stabilność i reakcję systemu, wnosząc istotny komponent antycypacyjny. Sekcja 1.2 przedstawia już pewne wstępne wnioski matematyczne dotyczące tego, jak antykruchosc można odwzorować na przetwarzanie neuronalne. W dalszej części konsolidujemy i formułujemy perspektywę zawartą w literaturze dotyczącej spektrum zachowań. Jednakże, aby wprowadzić rolę antykruchości w spektrum zachowań neuronalnych, w manuskrypcie stabilność odnosi się do zdolności systemów neuronowych (tj. pojedynczych neuronów lub sieci neuronowych) do powrotu do stanu stacjonarnego, gdy niestabilne zaburzenie przestaje działać i przywrócona zostaje równowaga między siłami działającymi w systemie. Odporność w tym kontekście odnosi się do wewnętrznych mechanizmów, które pozwalają systemowi neuronowemu akomodować zaburzenia lub zmiany sygnału wejściowego. Odporność jest tutaj używana do scharakteryzowania zdolności systemu neuronowego do odzyskiwania sprawności po różnorodnych zmianach parametrów. Wreszcie, krótkoterminowe lub długoterminowe zmiany w procesie neuronowym lub sieci neuronowej, które zachodzą podczas obecności bodźca, określane są mianem adaptacji. Definicje te są poparte badaniami eksperymentalnymi.

Matematycznie, antykruchosc można zdefiniować jako nieliniową, wypukłą odpowiedź na dobrze zdefiniowaną funkcję wypłaty, wykazywaną przez układ w kontekście zmienności. Definicja ta zakłada, że antykruchosc jest lokalną właściwością układu dynamicznego w określonym obszarze przestrzeni wejściowej układu. Sekcja 1.2 zawiera już niezbędne definicje, które pomogą czytelnikowi zrozumieć koncepcje zastosowania antykruchości do przetwarzania neuronowego. W kontekście neuronalnym Calaim i współpracownicy przedstawili nowatorską interpretację geometryczną dynamiki i funkcji sieci impulsowych (Calaim i in., 2022). W systematycznym i dogłębnym badaniu odporności na poziomie obwodów na zaburzenia parametrów, śmierć neuronów i szum pozorny wykazali, że napięcia podprogowe neuronów są ograniczone do obszaru wypukłego w podprzestrzeni napięciowej.

Aby rozszerzyć spektrum, opieramy się na kluczowych wnioskach z analizy układów dynamicznych, sformalizowanych zarówno w pracach Krakovská i in. (2021), jak i Meyer (2015). W pracy tej zakładamy, że: 1) odporność na powtarzające się zmiany zmiennych stanu koreluje z odpornością na zmiany parametrów

wynikające ze zjawiska krytycznego spowolnienia (tj. regulacji aktywności homeostatycznej (HAR) w pojedynczych neuronach); 2) sieci neuronowe zapewniają odporność na fluktuacje zmiennych stanu, które mogą różnić się od tych, które sprzyjają regeneracji po nich (tj. konkurencji i współpracy w populacji neuronów kodujących pojedyncze strumienie sensoryczne i motoryczne poprzez zasadę „zwycięzca bierze wszystko” (WTA)); oraz 3) wskaźniki regeneracji mają znaczenie dla odporności biologicznej (tj. uczenia się korelacji czasowej poprzez zmienność uczenia się Hebba (HL)).

W naszym dążeniu, dynamiczna analiza neuronowych systemów przetwarzania musi zostać uzupełniona o formalne pomiary każdego zachowania w spektrum stabilności-odporności. W tym względzie badanie Bramsona (2010) wykazało, że systemy wykazujące sprzężenie zwrotne, nieliniowość, heterogeniczność i zależności ścieżkowe muszą zostać ujęte w zunifikowanym obiekcie matematycznym. W badaniu wykorzystano ramy modelu Markowa przedstawione powyżej, aby ustalić formalne definicje kilku pojęć ze spektrum zachowań systemów dynamicznych: solidnych, niezawodnych, zrównoważonych, odpornych, odzyskiwalnych, stabilnych i statycznych, a także ich odpowiedników: podatnych, wrażliwych i kruchych. Co ciekawe, najnowsze, losowo połączone modele pobudzające i hamujące populacji neuronów impulsowych rzucają światło na zdolność populacji neuronów do reagowania na dowolne zmiany bodźców wejściowych, zależność dynamiki populacji od rodzaju szumu oraz wpływ połączeń rekurencyjnych na dynamikę (Brunel (2000)).

W badaniu Luboeinski i in. (2023) zaproponowano model stabilizacji sieci rekurencyjnych poprzez zwiększenie średniej siły samosprężenia jednostek sieci. W przypadku obu topologii autorzy zaobserwowali gwałtowne przejście od niestabilności do stabilności asymptotycznej, co potwierdza cechy odziedziczonej antykruchości. Zjawisko to jest dodatkowo uwydatnione przez obserwację, że średnia siła samosprężenia wymagana do stabilizacji rośnie w tempie znacznie wolniejszym niż rozmiar systemu, co wskazuje, że stopniowo buduje on zdolność do osiągnięcia stabilności poprzez stopniowy wzrost samoregulacji jednostek. Te wszechstronne ramy ponownie dowodzą potrzeby rozszerzenia spektrum zachowań w obszarze układów dynamicznych o zadanej dynamice. Jednakże podejście w badaniu było zorientowane na teorię grafów i statystykę, podczas gdy praktyczna dynamika pętli zamkniętej nie była centralna. To motywuje naszą perspektywę do wyróżnienia się jako dążenia do systemów sterowania ze sprzężeniem zwrotnym w celu opisanie antykruchości.

3.3.3 Wgląd w neuronalną indukowaną antykruchość

Z punktu widzenia ilościowego, prowadzone są badania nad wykorzystaniem probabilistycznych technik oceny odporności złożonych układów dynamicznych w pętlach sterowania ze sprzężeniem zwrotnym. Jak podkreślono w badaniu Balchanos (2012), regulator ze sprzężeniem zwrotnym odpowiada za odzyskiwanie wydajności systemu poprzez zastosowanie różnych strategii rekonfiguracji i strategiczne aktywowanie niezbędnej redundancji. W związku z tym wpływ niepewności i zmienności na działanie systemu jest odzwierciedlany przez czynniki zakłócające. Obserwacje te są bezpośrednio istotne w dziedzinie systemów biologicznych. W tym kierunku, badanie Arnoldiego i in. (2016) dotyczące odporności, reaktywności i zmienności redefiniuje spektrum stabilnych, odpornych, odpornych i adaptacyjnych zachowań w ramach metryk opartych na geometrycznych wektorach własnych. Parametryzowane za pomocą wartości własnych odległości od punktów równowagi, metryki te odzwierciedlają separację skali czasowej i redukcję rzędu poprzez parametry ruchu wektorów własnych.

jego wynik na długich ogonach (Taleb, 2020) poprzez integrację informacji sensorycznych i motorycznych, z których każda charakteryzuje się innymi właściwościami szumowymi (tj. niezawodnością), w sposób

minimalizujący niepewność w ogólnym oszacowaniu (van Beers i in., 2002). Takie obserwacje są jeszcze lepiej uchwycone w ramach odkrywania możliwości poprzez percepcję i działanie (Chavez-Garcia i in., 2016). Dokładniej rzecz ujmując, wydajność zadania sensomotorycznego jest maksymalizowana poprzez dostosowanie dynamiki systemu w warunkach ograniczeń fizycznych i obliczeniowych (Ogawa i in., 2006).

Wydaje się, że kontinuum stabilność-odporność-odporność-adaptacyjność w sterowaniu sensomotorycznym również podlega hierarchicznej strukturze (Nagata i in. (1994)), która wyjaśnia interakcje między różnymi skalami czasowymi integracji sensorycznej, generowania planu ruchowego i kompensacji zakłóceń, ogólnie rzecz biorąc pod wyraźnym wpływem niepewności transformacji współrzędnych (Schlicht i Schrater (2007)). Pogląd ten jest następnie rozwijany przez Bettingera i Fristona (2023) w pracy Bettingera i Fristona (2023), którzy przedstawili koncepcję „stabilności poprzez zmianę”, obejmującą „powrót do stabilności” w wariacyjnym modelu homeostazy. Perspektywa ta zmaterializowała się w badaniu Parra i współpracowników (2017) w pracy Parra i Fristona (2017), w którym generatywny model bayesowski kodował przekonania o niepewności pomimo zaszumionych danych sensorycznych i zmiennych warunków środowiskowych.

W tym momencie oceniamy, jak początkowy aparat matematyczny opisujący zasady antykruchości można zastosować w dziedzinie układów dynamicznych, takich jak sieci neuronowe, poprzez badanie znaczenia składowej czasowej w zmianach struktury, funkcji i danych wejściowych. Jest to kluczowy element, który pozwala nam definiować, mierzyć i integrować zasady antykruchości w teorii sterowania. Te interdyscyplinarne badania są obecnie prowadzone przez Grupę Antykruchości Stosowanej. W celu wprowadzenia do antykruchości stosowanej zachęcamy czytelnika do zapoznania się z pracą Axenie i in. (2024), w której klasyfikujemy antykruchosc w różnych skalach: od antykruchości wewnętrznej (tj. opisującej wewnętrzną dynamikę czasową układu dynamicznego), przez antykruchosc dziedziczną (tj. determinowaną przez lokalne interakcje układu z innymi układami), aż po antykruchosc indukowaną (tj. zadaną dynamikę w paradygmacie sterowania ze sprzężeniem zwrotnym w pętli zamkniętej). Główne elementy teorii sterowania antykruchego zostały dopracowane w wielu instancjach: Axenie i Saveriano (2023), Axenie i Grossi (2023), Axenie i in. (2022) i obejmują:

- separacja skali czasowej
- zbędna nadmierna rekompensata
- zmienna struktura i dynamika atraktora

Co ciekawe, zasady antykruchości znalazły zastosowanie nawet poza naszą teoretyczną formułą kontroli, w odniesieniu do antykruchości opartej na spełnieniu ograniczeń w sieciach (Pineda i in., 2019), odporności i kruchości opartej na dynamice sprzężenia zwrotnego (Kwon i Cho, 2008), antykruchości w systemach systemów (Johnson i Gheorghe, 2013) oraz kryteriów antykruchości dla modelowania układów dynamicznych (de Bruijn i in., 2020). Ten szeroki kontekst konsoliduje naszą perspektywę i lepiej ją ujmują w domenie układów dynamicznych.

Aby ułatwić prace koncepcyjne, które rozwijamy z tej perspektywy, zakotwiczymy wyjaśnienia w ograniczonym, ale reprezentatywnym zestawie neuronalnych modeli sterowania sensomotorycznego. Wstępne badania ujmujące neuronalne przetwarzanie sensomotoryczne w teorii sterowania obejmowały klasyczne aspekty sterowalności i stabilizacji układów dynamicznych (Levin i Narendra, 1993), obserwowalności i identyfikacji (Levin i Narendra, 1996) oraz sterowania ze sprzężeniem zwrotnym w pętli zamkniętej (Narendra, 1996).

Opracowując model obliczeniowy modeli odwrotnych dla dowolnych strumieni sensorycznych i motorycznych,

Hanuschkin i współpracownicy (2013) w swojej pracy Hanuschkin i in. (2013), wykazali, że uczenie się Hebba może być wykorzystane do uczenia modeli odwrotnych stosowanych w procesach kompensacyjnych, gdy w regule uczenia nie są używane żadne heterosynaptyczne terminy konkurencyjne. Ten interesujący wynik jest dodatkowo poszerzony przez bardzo wnikliwe badanie Zenke i współpracownicy (2017) w swojej pracy Zenke i in. (2017), w którym stabilność sprzężenia zwrotnego w zamkniętej pętli reguł plastyczności Hebba została osiągnięta poprzez homeostatyczne szybkie procesy kompensacyjne. To silnie motywuje teorię antykruchości, w której „składniki” paradoksu temporalnego Zenke i współpracownicy (2017) są sprytnie wykorzystywane w połączeniu, aby wykorzystać przetwarzanie neuronowe. Wreszcie, w stosunkowo wyczerpującym, dynamicznym ujęciu systemów uczenia się Hebba w rekurencyjnych sieciach neuronowych, Siri i współpracownicy (2008) w swojej pracy Siri i in. (2008) wykorzystali aparat układu dynamicznego do ukształtowania kompletnej analizy behawioralnej uczenia się Hebba w pętli zamkniętej, wykorzystując wykładniki Lyapunowa oraz kształt krzywizny Jakobianu układu pętli zamkniętej. Analizując „wykres wpływów”, przeanalizowali i omówili wzajemne oddziaływanie dodatnich i ujemnych pętli sprzężenia zwrotnego oraz ich wpływ na zachowanie sieci w obliczu zakłóceń.

W naszej obecnej perspektywie analizujemy charakterystykę reprezentatywnych modeli sensomotorycznych przez pryzmat antykruchości i jej trzech głównych składników. Dodatkowo, aby dostosować ramy do przetwarzania neuronowego, ograniczamy się do analizy jedynie trzech głównych elementów dynamicznych (obliczeniowych): odpowiednio HAR, WTA i HL. Jako przykładowe systemy rozważamy **nienadzorowane uczenie się sieci relacji sensomotorycznych Cooka** i in. (2010), samoorganizującą się sigma-pi sieć sensomotoryczną Webera i Wermtera (2007), sieć oddziałujących funkcji bazowych Firouziego i in. (2014) oraz sieć uczenia korelacji sensomotorycznych Axeniego i in. (2016). Nasz wybór modeli i mechanizmów obliczeniowych jest motywowany licznymi niedawnymi badaniami obliczeniowymi i eksperymentalnymi podkreślającymi istotną rolę „kanonicznych” mechanizmów obliczeniowych (tj. HAR, WTA, HL) w zachowaniach przetwarzania neuronowego. Najistotniejsze badania dla naszego obecnego zainteresowania opisem przetwarzania neuronowego w ramach koncepcji antykruchości koncentrują się na przeniesieniu tych zasad do systemów technicznych o zamkniętej pętli. Należą do nich badania obliczeniowe Cooka i in. (2010) oraz Firouziego i in. (2014) oraz badania robotyczne Webera i Wermtera (2007) oraz Axeniego i in. (2016). W tym kontekście niezwykle interesujące badanie Towera (2024) wprowadza koncepcję SAI systemów wieloskładnikowych, takich jak systemy komórkowe. Co ciekawe, jego koncepcja koncentruje się na zestawie modeli opisujących „potencjalny koszt dla systemu tworzenia niestabilnych komponentów, a w niektórych przypadkach koszt ich aktywnej degradacji”. Perspektywa ta jest również uwzględniona w koncepcji antykruchości przetwarzania neuronowego. Biorąc pod uwagę szeroki zakres wzorców impulsów neuronalnych, ich dynamika (tj. niestabilność aktywności neuronalnej lub oscylacje na poziomie HAR) przyczynia się do wzorca interakcji (tj. modulacji poprzez hamowanie, pobudzenie degenerujące się w niestabilność, poprzez WTA i HL) z innymi komórkami w obrębie populacji neuronalnych lub pomiędzy nimi. Jednocześnie ten wzorec interakcji determinuje źródło stresu dla każdej komórki, którego przetwarzanie jest superpozycją projekcji sensorycznych i lokalnych interakcji (np. HAR + WTA + HL). Tower definiuje niestabilność jako „względna skłonność składnika systemu do ulegania fizycznemu rozpadowi jego struktury, spontanicznie lub poprzez działanie czynnika degradującego”. Teoria antykruchości wykracza poza to sformułowanie, proponując również mechanizmy wykorzystujące „działania degradujące” poprzez budowanie (antycypacyjnej) zdolności do redundantnego przeceniania spontanicznych efektów struktury lub działań zewnętrznych. Działania te w teorii antykruchości są synonimem eliminacji uszkodzeń (tj. degradacji z korzyściami oprócz uwolnienia energii) i adaptacji do zmian środowiskowych w ramach SAI poprzez dążenie do krytyczności. Aspekty te definiują jednoczący charakter obu ram i ich potencjał do formalnego uchwycenia szerszego spektrum behawioralnego przetwarzania komórek neuronalnych. Wreszcie, podobnie jak w teorii antykruchości, SAI działa na wielu poziomach organizacji biologicznej, obejmując wewnętrzną dynamikę komponentów, krótkozasięgową dynamikę interakcji na poziomie komponentów oraz dalekozasięgowe interakcje na poziomie systemu.

