



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2021-0124960
(43) 공개일자 2021년10월15일

(51) 국제특허분류(Int. Cl.)
G06N 3/04 (2006.01) G06N 3/063 (2006.01)
G06N 3/08 (2006.01)
(52) CPC특허분류
G06N 3/049 (2013.01)
G06N 3/0454 (2013.01)
(21) 출원번호 10-2021-7016977
(22) 출원일자(국제) 2019년11월14일
심사청구일자 없음
(85) 번역문제출일자 2021년06월03일
(86) 국제출원번호 PCT/EP2019/081373
(87) 국제공개번호 WO 2020/099583
국제공개일자 2020년05월22일
(30) 우선권주장
62/768,927 2018년11월18일 미국(US)

(71) 출원인
인나테라 나노시스템즈 비.브이.
네덜란드, 2289 이엑스 리즈스비르크, 파트리즈
스베그 20
(72) 발명자
쿠마르 수미트 수월
네덜란드 2628 시디 델프트 메켈베그 4 (티유디-
이더블유아이-시에이에스) 인나테라 나노시스템즈
비.브이.
지자조 아미르
네덜란드 2628 시디 델프트 메켈베그 4 (티유디-
이더블유아이-시에이에스) 인나테라 나노시스템즈
비.브이.
(74) 대리인
특허법인명신, 남완용


전체 청구항 수 : 총 30 항

(54) 발명의 명칭 스파이킹 뉴럴 네트워크

(57) 요약

입력 패턴 신호를 분류하기 위한 스파이킹 뉴럴 네트워크로서, 하드웨어 또는 하드웨어와 소프트웨어의 조합으로 구현된 복수의 스파이킹 뉴런, 및 네트워크를 형성하기 위해 스파이킹 뉴런들을 상호 연결하는 복수의 시냅스 요소를 포함한다. 각 시냅스 요소는 시냅스 입력 신호를 수신하고 시냅스 입력 신호에 가중치를 적용하여 시냅스 출력 신호를 생성하도록 적응되며, 시냅스 요소는 각 시냅스 요소에 의해 적용되는 가중치를 조정하도록 구성될 수 있으며, 스파이킹 뉴런들 각각은 하나 이상의 시냅스 요소로부터 하나 이상의 시냅스 출력 신호를 수신하고, 수신된 하나 이상의 시냅스 출력 신호에 응답하여 시공간 스파이크 열 출력 신호를 생성하도록 적응된다.

대표도 - 도2



(52) CPC특허분류

G06N 3/063 (2013.01)

G06N 3/088 (2013.01)

명세서

청구범위

청구항 1

입력 패턴 신호를 분류하기 위한 스파이킹 뉴럴 네트워크에 있어서,

하드웨어 또는 하드웨어와 소프트웨어의 조합으로 구현된 복수의 스파이킹 뉴런, 및 상기 스파이킹 뉴런들을 상호 연결하여 네트워크를 형성하는 복수의 시냅스 요소를 포함하며,

각각의 시냅스 요소는 시냅스 입력 신호를 수신하고 가중치를 상기 시냅스 입력 신호에 적용하여 시냅스 출력 신호를 생성하도록 적응되며, 상기 시냅스 요소는 각 시냅스 요소에 의해 적용되는 가중치를 조정하도록 구성 가능하며,

상기 스파이킹 뉴런들 각각은 상기 시냅스 요소들의 하나 이상으로부터 상기 시냅스 출력 신호들의 하나 이상을 수신하고, 수신된 하나 이상의 시냅스 출력 신호에 응답하여 시공간 스파이크 열 출력 신호를 생성하도록 적응되며,

상기 스파이킹 뉴럴 네트워크는 상기 시냅스 요소들의 제1 서브-세트로부터 시냅스 출력 신호를 수신하도록 연결된 상기 스파이킹 뉴런들의 제1 서브-세트를 포함하는 제1 서브-네트워크를 포함하며,

상기 제1 서브-네트워크는 상기 제1 시냅스 요소 서브-세트에 적용된 서브-네트워크 입력 패턴 신호에 응답하여 상기 제1 스파이킹 뉴런 서브-세트로부터 서브-네트워크 출력 패턴 신호를 생성하도록 적응되며,

상기 제1 시냅스 요소 서브-세트의 가중치는 서브-네트워크 입력 패턴 신호의 훈련 세트에서 상기 서브-네트워크를 훈련함으로써 구성되고, 상기 서브-네트워크 출력 패턴 신호는 상기 훈련 세트의 모든 고유한 서브-네트워크 입력 패턴에 대해 상이하며, 상기 고유한 정도는 상기 제1 스파이킹 뉴런 및 시냅스 요소 서브-세트의 작동 매개 변수를 통해 제어 가능한, 스파이킹 뉴럴 네트워크.

청구항 2

제 1 항에 있어서,

각각의 고유한 서브-네트워크 출력 패턴 신호 사이의 각각의 거리는 미리 결정된 임계 값보다 크고, 상기 거리는 출력 패턴 메트릭에 의해 측정되는, 스파이킹 뉴럴 네트워크.

청구항 3

제 1 항에 있어서,

출력 패턴 메트릭에 의해 측정된 바와 같은, 2개의 상이한 각각의 서브-네트워크 입력 패턴 신호에 응답하여 생성된 상기 서브-네트워크의 2개의 출력 패턴 신호 사이의 각각의 거리가 상기 훈련 세트의 모든 서브-네트워크 입력 패턴 신호에 대해 최대화되도록, 상기 스파이킹 뉴런 및 시냅스 요소가 구성되는, 스파이킹 뉴럴 네트워크.

청구항 4

제 3 항에 있어서,

상기 출력 패턴 신호가 상기 입력 패턴 신호들의 특징들 사이를 구별하는데 필요한 적어도 제1 최소 감도 임계 값을 충족할 때까지, 상기 각각의 거리가 최대화되는, 스파이킹 뉴럴 네트워크.

청구항 5

제 1 항 내지 제 4 항 중 어느 한 항에 있어서,

상기 제1 시냅스 요소 서브-세트의 가중치는, 특정 시간에 원하는 출력 뉴런에서 그리고 상기 서브-네트워크 입력 패턴 신호의 적용과 동시에 다른 뉴런에서 스파이크를 유도함으로써, 반-지도 훈련 방법론을 사용하여 서브-

네트워크 입력 패턴 신호의 훈련 세트에서 상기 서브-네트워크를 훈련하여 구성되며, 상기 서브-네트워크는 원하는 서브-네트워크 출력 패턴으로 응답하도록 구성된, 스파이킹 뉴럴 네트워크.

청구항 6

제 5 항에 있어서,

특정 입력 패턴에 대한 고유한 응답을 얻기 위해 원하는 스파이크가 특정 시간에 인위적으로 유도되는, 스파이킹 뉴럴 네트워크.

청구항 7

제 5 항에 있어서,

원하는 시간에 상기 서브-네트워크의 뉴런(n)에서 인위적으로 스파이크를 유도함으로써, 상기 서브-네트워크의 이전 계층들에 있는 뉴런들과 상기 뉴런(n) 사이의 관계의 특성이 인과적, 반-인과적 또는 무-인과적으로 설정되는, 스파이킹 뉴럴 네트워크.

청구항 8

제 1 항 내지 제 4 항 중 어느 한 항에 있어서,

상기 제1 시냅스 요소 서브-세트의 가중치는, 원하는 출력 뉴런과 상기 서브-네트워크의 이전 계층들에 있는 뉴런들 간의 인과 관계의 식별을 가능하게 하고, 이 인과관계 경로를 따라 개재하는 시냅스 요소의 가중치를 조정하는 인과사슬 스파이크-타이밍-중속 가소성(CC-STDP) 학습 규칙을 사용하여 구성되는, 스파이킹 뉴럴 네트워크.

청구항 9

제 8 항에 있어서,

CC-STDP 학습 규칙을 사용하여, 상기 서브-네트워크 출력 패턴 신호는 특정 서브-네트워크 입력 패턴 신호 및 정확한 발사 시간에 응답하여 발사된 상기 서브-네트워크의 출력 뉴런들의 상이한 집단을 향해 조종되어 특정 서브-네트워크 출력 패턴 신호에 도달할 수 있는, 스파이킹 뉴럴 네트워크.

청구항 10

제 8 항에 있어서,

상기 CC-STDP 학습 규칙은 발사 이벤트가 상기 서브-네트워크의 후속 계층들에서 뉴런의 발사에 기여하는 경우에만 상기 발사 이벤트에 기초하여 상기 제1 시냅스 요소 서브-세트의 가중치를 조정하는, 스파이킹 뉴럴 네트워크.

청구항 11

제 8 항에 있어서,

CC-STDP 학습 규칙을 사용하는 상기 훈련은 특정 시간에 상기 제1 스파이킹 뉴런 서브-세트의 뉴런에서 스파이크의 생성을 유도, 억제, 또는 유도 및 억제하는 것을 포함하는, 스파이킹 뉴럴 네트워크.

청구항 12

제 11 항에 있어서,

뉴런에서 스파이크 생성을 유도하는 것은 바이어스 전압 입력에 의해 뉴런의 막을 막의 발사 임계 값을 초과하는 전압으로 구동하여 스파이크의 생성을 유도하거나, 또는 특정 시간에 뉴런의 출력에 인공 스파이크를 주입하는 것 포함하는, 스파이킹 뉴럴 네트워크.

청구항 13

제 11 항에 있어서,

뉴런에서 스파이크 생성을 억제하는 것은 뉴런의 막을 그 무반응 전압 또는 가능한 가장 낮은 전압으로 구동하거나, 스파이크 생성을 차단하거나, 뉴런에서 스파이크 생성을 비활성화하는 것을 포함하는, 스파이킹 뉴런 네트워크.

청구항 14

제 8 항에 있어서,

상기 CC-STDP 학습 규칙은 다음 규칙에 따라 뉴런(i)와 뉴런(j) 사이에 위치하는 시냅스 요소의 가중치 $w_{i,j}$ 를 변경하며:

$$\Delta w_{i,j} = \begin{cases} \delta w_{i,j} & \delta w_{i,j} > 0 \text{에 대해 } w_{j,k} \neq 0 \text{이고 } t_{spike\ k} > t_{spike\ j} \text{이고 } t_{spike\ k} > t_{spike\ i} \text{이면} \\ \delta w_{i,j} & \delta w_{i,j} < 0 \text{에 대해} \\ 0 & w_{j,k} = 0 \text{ 또는 } t_{spike\ k} \leq t_{spike\ i} \text{ 또는 } t_{spike\ k} \leq t_{spike\ j} \text{ 또는 } t_{spike\ k} = 0 \text{ 이면} \end{cases} \quad (1)$$

여기서 $\Delta w_{i,j}$ 는 뉴런(i)과 뉴런(j) 사이의 시냅스 요소에 대한 유효 가중치 변화이고, $w_{j,k}$ 는 후속 계층의 뉴런(j)과 뉴런(k) 사이의 시냅스 요소의 가중치이고, $t_{spike\ i}$, $t_{spike\ j}$ 및 $t_{spike\ k}$ 는 뉴런 i, j 및 k 각각에 대한 제2 규칙의 기본 매개 변수이고, $\delta w_{i,j}$ 는 상대적 스파이킹 시간으로 인한 뉴런(i)과 뉴런(j) 사이의 시냅스 요소의 가중치 변화이고 상기 제2 학습 규칙을 사용하여 계산할 수 있는, 스파이킹 뉴런 네트워크.

청구항 15

제 14 항에 있어서,

상기 제2 학습 규칙은 STDP 학습 규칙이고, $t_{spike\ i}$, $t_{spike\ j}$ 및 $t_{spike\ k}$ 는 뉴런(i, j, k)이 각각 스파이크하는 정확한 시간을 나타내는, 스파이킹 뉴런 네트워크.

청구항 16

제 1 항 내지 제 4 항 중 어느 한 항에 있어서,

상기 스파이킹 뉴런들 각각은 상기 수신된 하나 이상의 시냅스 출력 신호에 대하여 상기 뉴런의 응답을 조정하도록 구성 가능한, 스파이킹 뉴런 네트워크.

청구항 17

제 1 항 내지 제 4 항 중 어느 한 항에 있어서,

하나 이상의 발사 시간에 상기 스파이킹 뉴런들에 의해 스파이크가 생성되며, 상기 시냅스 요소 서브-세트 및 상기 뉴런 서브-세트 중 적어도 하나는 두 개의 고유한 서브-네트워크 입력 패턴 신호에 대해 발사하는 상기 뉴런 서브-세트의 두 세트의 발사 시간의 합집합이 상기 훈련 세트의 모든 서브-네트워크 입력 패턴 신호에 대해 최소화되도록 구성되는, 스파이킹 뉴런 네트워크.

청구항 18

제 17 항에 있어서,

상기 출력 패턴 신호가 상기 입력 패턴 신호의 특징들 사이를 구별하는데 필요한 적어도 제2 최소 감도 임계 값을 충족할 때까지 각각의 합집합이 최소화되는, 스파이킹 뉴런 네트워크.

청구항 19

제 1 항 내지 제 4 항 중 어느 한 항에 있어서,

상기 네트워크는 상기 시냅스 요소들의 제2 서브-세트로부터 시냅스 출력을 수신하도록 연결된 상기 스파이킹 뉴런들의 제2 서브-세트를 포함하는 제2 서브-네트워크를 포함하며,

상기 제2 서브-네트워크는 상기 제2 시냅스 요소 서브-세트에 적용된 제2 서브-네트워크 입력 패턴 신호를 수신하고, 상기 제2 뉴런 서브-세트로부터 대응하는 제2 서브-네트워크 출력 패턴 신호를 생성하도록 적응되며,

상기 제2 서브-네트워크 출력 패턴 신호가 상기 제2 서브-네트워크 입력 패턴 신호의 모든 고유한 특징에 대해 고유하도록, 상기 제2 시냅스 요소 서브-세트의 구성이 조정되며,

상기 네트워크는 상기 시냅스 요소의 제3 서브-세트로부터 시냅스 출력을 수신하도록 연결된 상기 스파이킹 뉴런의 제3 서브-세트를 포함하는 제3 서브-네트워크를 포함하며,

상기 제1 및 제2 서브-네트워크 출력 패턴 신호는 상기 제3 서브-네트워크의 입력 패턴 신호이며,

상기 제3 서브-네트워크 출력 패턴 신호가 제1 및 제2 서브-네트워크의 입력 패턴 신호의 모든 고유한 특징 및 이들의 고유한 조합에 대해 고유하도록, 상기 제3 시냅스 요소 서브-세트의 구성이 조정되고, 제1 및 제2 서브-네트워크로부터의 입력 패턴 신호에 존재하는 특징이 상기 제3 서브-네트워크에 의해 인코딩되는, 스파이킹 뉴런 네트워크.

청구항 20

제 19 항에 있어서,

상기 제1 및 제2 서브-네트워크로부터의 입력 패턴 신호는 상기 입력 패턴 신호의 특정 특징의 중요도에 따라 가중치가 부여되도록, 상기 제3 서브-네트워크의 시냅스 요소가 구성되는, 스파이킹 뉴런 네트워크.

청구항 21

제 1 항 내지 제 4 항 중 어느 한 항에 있어서,

상기 네트워크는 시냅스 요소들 및 스파이킹 뉴런들의 다수 서브-네트워크를 포함하고, 여기서 서브-네트워크 출력 패턴 신호는 서브-네트워크 입력 패턴 신호의 모든 고유한 특징에 대해 고유하며,

상기 네트워크는 네트워크에서 특정 순차적 순서를 갖는 여러 계층으로 나눌 수 있으며,

상기 다수 서브-네트워크는 각 서브-네트워크가 속하는 다수의 계층의 특정 순차적 순서로 인스턴스화되는, 스파이킹 뉴런 네트워크.

청구항 22

제 1 항 내지 제 4 항 중 어느 한 항에 있어서,

상기 시냅스 요소는 구성 가능한 스위치 행렬로서 배열되는, 스파이킹 뉴런 네트워크.

청구항 23

제 1 항 내지 제 4 항 중 어느 한 항에 있어서,

상기 뉴런, 시냅스 요소, 뉴런 및 시냅스 요소의 상호 연결 토폴로지, 및 상기 뉴런 네트워크의 출력 구성 중 적어도 하나의 구성 정보는 구성 메모리에 저장되고,

상기 구성 정보는 상기 뉴런 네트워크가 초기화 상태가 될 때 상기 구성 메모리로부터 로딩되는, 스파이킹 뉴런 네트워크.

청구항 24

제 1 항 내지 제 4 항 중 어느 한 항에 있어서,

한 세트의 뉴런이 하나 이상의 뉴런 템플릿 네트워크에 배열되고, 특정 뉴런 템플릿 네트워크의 뉴런들은 상기 뉴런 네트워크의 서브-네트워크를 형성하며,

상기 서브-네트워크 출력 패턴 신호는 상기 서브-네트워크 입력 패턴 신호의 모든 고유한 특징에 대해 고유하며,

상기 뉴런 네트워크의 각 템플릿 네트워크는 제 17 항에 따라 구성된 사전 훈련된 서브-네트워크로서 인스턴스화되는, 스파이킹 뉴런 네트워크.

청구항 25

제 1 항 내지 제 4 항 중 어느 한 항에 있어서,

상기 뉴럴 네트워크는 입력으로서 하나 이상의 샘플링된 아날로그 또는 디지털 입력 신호를 취하고 상기 입력 신호를 스파이킹 뉴럴 네트워크 입력 패턴 신호의 대표적인 세트에 변환하도록 구성되는, 스파이킹 뉴럴 네트워크.

청구항 26

제 1 항 내지 제 4 항 중 어느 한 항에 있어서,

상기 뉴럴 네트워크의 출력 패턴 신호는 하나 이상의 출력 클래스로 분류되는, 스파이킹 뉴럴 네트워크.

청구항 27

하드웨어 또는 하드웨어와 소프트웨어의 조합으로 구현된 복수의 스파이킹 뉴런, 및 상기 스파이킹 뉴런들을 상호 연결하여 네트워크를 형성하는 복수의 시냅스 요소를 포함하는 스파이킹 뉴럴 네트워크를 사용하여 입력 패턴 신호를 분류하는 방법으로서,

상기 시냅스 요소들 각각은 시냅스 입력 신호를 수신하고 가중치를 상기 시냅스 입력 신호에 적용하여 시냅스 출력 신호를 생성하도록 적응되며, 상기 시냅스 요소들은 각 시냅스 요소에 의해 적용되는 가중치를 조정하도록 구성 가능하며,

상기 스파이킹 뉴런들 각각은 상기 시냅스 요소들의 하나 이상으로부터 상기 시냅스 출력 신호들의 하나 이상을 수신하고, 수신된 하나 이상의 시냅스 출력 신호에 응답하여 시공간 스파이크 열 출력 신호를 생성하도록 적응되며,

상기 방법은:

상기 스파이킹 뉴럴 네트워크의 제1 서브-네트워크를 정의하는 단계로서, 상기 제1 서브-네트워크는 상기 시냅스 요소들의 제1 서브-세트로부터 시냅스 출력 신호를 수신하도록 연결된 상기 스파이킹 뉴런들의 제1 서브-세트를 포함하는, 단계;

서브-네트워크 입력 패턴 신호의 훈련 세트에서 상기 서브-네트워크를 훈련함으로써 상기 제1 시냅스 요소 서브-세트의 가중치를 구성하여, 상기 서브-네트워크 출력 패턴 신호가 상기 훈련 세트의 모든 고유한 서브-네트워크 입력 패턴에 대해 고유하도록 하는 단계로서, 여기서 상기 고유의 정도는 상기 제1 스파이킹 뉴런 및 시냅스 요소 서브-세트의 작동 매개 변수를 통해 제어 가능한, 단계;

상기 스파이킹 뉴럴 네트워크의 제1 서브-네트워크에 서브-네트워크 입력 패턴 신호를 적용하는 단계로서, 상기 제1 서브-네트워크는 상기 시냅스 요소들의 제1 서브-세트로부터 시냅스 출력 신호를 수신하도록 연결된 상기 스파이킹 뉴런들의 제1 서브-세트를 포함하는, 단계; 및

상기 서브-네트워크 입력 패턴 신호에 응답하여 상기 제1 스파이킹 뉴런 서브-세트에 의해 생성된 서브-네트워크 출력 패턴 신호를 수신하는 단계로서, 상기 출력 패턴 신호는 상기 입력 패턴 신호의 하나 이상의 특징을 식별하는, 단계;

를 포함하는, 방법.

청구항 28

입력 신호의 미리 결정된 특징을 분류하는 방법으로서,

제 27 항에 따른 스파이킹 뉴럴 네트워크를 구축하고 훈련하는 단계;

하나 이상의 샘플링된 입력 신호를 상기 뉴럴 네트워크에 제출하는 단계; 및

상기 뉴럴 네트워크의 하나 이상의 클래스에서 하나 이상의 샘플링된 입력 신호의 특징을 분류하는 단계;

를 포함하는, 방법.

청구항 29

스파이킹 뉴럴 네트워크의 서브-네트워크로 사용하기 위한 스파이킹 뉴런들의 하나 이상의 템플릿 네트워크의

구성에 대한 정보를 포함하는 템플릿 라이브러리에 있어서,

각각의 템플릿 네트워크는 시냅스 요소 세트로부터 시냅스 출력을 수신하도록 연결된, 하드웨어 또는 하드웨어 및 소프트웨어의 조합으로 구현된 스파이킹 뉴런 세트를 포함하고,

각각의 템플릿 네트워크는 상기 시냅스 요소 세트에 적용된 템플릿 네트워크 입력 패턴 신호를 수신하고, 상기 뉴런 세트로부터 대응하는 템플릿 네트워크 출력 패턴 신호를 생성하도록 적응되며,

상기 시냅스 요소 세트의 구성은 템플릿 네트워크 입력 패턴 신호의 훈련 세트에 대해 템플릿 네트워크를 훈련 시킴으로써 조정되어, 상기 템플릿 네트워크 출력 패턴 신호가 상기 훈련 세트의 모든 고유한 템플릿 네트워크 입력 패턴 신호에 대해 고유하게 되며, 여기서 상기 고유한 정도는 상기 스파이킹 뉴런 및 시냅스 요소의 제1 서브-세트의 작동 매개 변수를 통해 제어할 수 있으며,

상기 스파이킹 뉴런 네트워크의 서브-네트워크가 특정 작업을 수행하기 위해 사전 훈련된 방식으로 상기 템플릿 네트워크의 구성에 대한 정보를 기초로 인스턴스화될 수 있도록, 상기 훈련 세트는 상기 특정 작업을 수행하도록 상기 템플릿 네트워크를 훈련시키는 데 사용되는, 템플릿 라이브러리.

청구항 30

스파이킹 뉴런 네트워크를 구성하는 방법으로서,

제 29 항에 따른 템플릿 라이브러리로부터 하나 이상의 템플릿 네트워크 또는 하나 이상의 템플릿 네트워크의 구성에 대한 정보를 획득하는 단계; 및

상기 템플릿 네트워크가 수행하도록 사전 훈련된 특정 작업을 상기 스파이킹 뉴런 네트워크의 서브-네트워크가 수행할 수 있도록, 상기 하나 이상의 템플릿 네트워크를 상기 스파이킹 뉴런 네트워크의 상기 서브-네트워크로서 인스턴스화하는 단계;

를 포함하는, 방법.

발명의 설명

기술 분야

[0001] 본 개시는 일반적으로 스파이킹 뉴런 네트워크(spiking neural networks)을 구성하는 것에 관한 것이다. 보다 구체적으로는, 배타적이지는 않지만, 스파이킹 뉴런들로 구축된 패턴 인식기를 구성하는 것과 고유한 응답 방법을 사용하는 구성 방식으로 스파이킹 뉴런 네트워크를 구축하는 시스템 및 방법과 관련된다.

배경 기술

[0002] 자동 신호 인식(ASR: Automatic Signal Recognition)은 신호를 구성하는 특징을 식별하여 신호를 인식하는 것을 말한다. ASR은 다양한 응용에서 이용되며, 예를 들어 화자의 음성과 음성/언어 인식 시스템에서 구어를 인식하고, 심전도(ECG)에서 부정맥을 인식하고, 동작-제어 시스템에서 제스처의 모양을 결정하는 데 사용된다. ASR은 일반적으로 입력 신호의 짧은 샘플에 존재하는 패턴을 규정하여 수행되므로 정확한 패턴 인식 능력은 효과적인 ASR 시스템의 기본이다.

[0003] ASR 시스템을 위한 입력 신호를 유도하기 위해 어떤 물리량을 측정하려면 여러 유형의 센서로부터 데이터를 융합하는 것이 필요할 수 있다. 예를 들어, 핸드헬드 입력 장치를 사용하여 손 제스처를 인식하려면 방향을 측정하기 위해 자이로스코프의 데이터와 모션을 측정하기 위해 가속도계의 데이터를 융합하는 것이 필요할 수 있다. 두 센서의 데이터를 결합하면 3차원 공간에서 제스처를 감지할 수 있다.

[0004] 일반적으로, 데이터 융합은, 개별 소스들로부터의 데이터의 해석에서 불확실성을 줄이기 위해, 서로 다른 잠재적으로 이질적인 소스로부터 수집된 데이터의 통합을 의미한다. 융합 프로세스 중에, 서로 다른 입력 신호들의 필수적인 특징이 융합된 신호에서 적절하게 표현되는 것이 중요하다.

[0005] 패턴 인식 및 융합은 일반적으로 마이크로프로세서 및/또는 디지털 신호 프로세서를 사용하여 수행되며, 둘 다 저장된 프로그램 아키텍처를 구현한다. 이 아키텍처는 스트리밍 데이터 분석에서 본질적으로 비효율적이다. 단일 프로세서에서, 패턴의 추출 및 인식은 순차적으로 수행된다. 이는 패턴 추출 및 식별이 일반적이고 단순한 명령 세트(예를 들면 RISC 또는 CISC 명령 세트)의 측면에서 실현되어, 신호 샘플의 모든 패턴에 대해 긴 실행

시퀀스를 생성하기 때문이다. 입력 신호의 복잡한 패턴은 더 복잡한 신호 처리 알고리즘의 사용이 필요하며, 이것은, 패턴 인식 엔진의 실시간 응답이 필요한 시스템에서, 프로세서에 대해 더 높은 클럭 주파수의 사용을 추가로 요구한다. 전력이 제한된 장치(예를 들어, 휴대용 전자 장치, 웨어러블 장치 등)에서는 이것이 가능하지 않다. 또한, 순차적 실행 패러다임으로 인해, 패턴의 복잡성과 레퍼토리의 증가에 따라 마이크로프로세서에서 패턴 인식 작업의 대기 시간과 전력 손실이 크게 증가한다. 입력 신호에 잡음이 있으면 분석이 더욱 복잡해지고 성능과 효율성이 저하된다.

[0006] 데이터 융합은 마이크로프로세서에서 비본질적인 동작이다. 이는 입력 신호 또는 데이터 스트림이 융합되기 전에, 해당 정보 콘텐츠를 추출한 후 다른 스트림의 해당 콘텐츠와 결합해야 함을 의미한다. 결과적으로, 마이크로프로세서 구현에서, 융합을 위한 각 입력 신호/데이터 소스는 독립적인 패턴 인식 파이프라인에 의해 개별적으로 처리된 다음, 서로 다른 패턴 인식 결과를 결합하기 위해 규칙-기반 프레임워크가 수행된다. 이 접근 방식은, 각 입력 신호 또는 데이터 스트림에 대해, 패턴 인식 기반구조를 여러 번 호출해야 하므로, 전력 손실의 증가로 이어진다. 또한, 패턴 인식을 위한 로딩-저장(load-store) 아키텍처 마이크로프로세서 및 디지털 신호 프로세서(DSP)의 한계는, 패턴 복잡성이 증가함에 따라 이러한 패턴을 인식하는 데 드는 전력 및 대기시간 비용도 증가한다는 것을 의미한다. 대기 시간 비용은 클럭 주파수를 증가시켜 완화할 수 있지만, 이는 전력 손실을 추가로 증가시키면서 달성된다. 마찬가지로, 융합의 품질은 입력 신호에 대해 수행되는 처리 및 ASR의 복잡성, 융합되는 신호의 수 및 마이크로프로세서 또는 DSP의 연산 능력에 의해 제한된다. 처리의 순차적 특성은 융합-기반 ASR의 처리량을 감소시키므로, 신호의 패턴 복잡성이 증가함에 따라, 마이크로프로세서 또는 DSP를 사용하여 융합될 수 있는 입력 신호의 수가 감소한다.

[0007] 마이크로프로세서 구현에 대한 대안으로 인공 뉴럴 네트워크가 제안되었다. 스파이킹 뉴럴 네트워크(SNN)은 다수의 다양한 애플리케이션에서 ASR을 실현하는 유망한 수단이다. SNN은 정수 또는 실수 값 벡터가 아닌 하나의 이상의 정확한 타이밍(전압)의 스파이크 형태로 정보를 인코딩한다. 패턴 분류를 위한 연산은 아날로그 및 시간 도메인에서 효과적으로 수행된다. 이러한 이유로, SNN은 일반적으로 하드웨어에서 완전-맞춤형 혼합 신호 집적 회로로 구현된다. 이를 통해, 네트워크 크기가 더 작을 뿐만 아니라, 인공 뉴럴 네트워크보다 몇 배 더 적은 에너지 소비로 패턴 분류를 수행하는 것이 가능하다.

[0008] SNN은 시냅스에 의해 상호 연결된 스파이킹 뉴런들의 네트워크로 구성되며 시냅스는 스파이킹 뉴런들 사이의 연결의 강도를 결정한다. 이 강도는 가중치로 표현되며, 가중치는 시냅스-후 뉴런의 입력에 대한 시냅스-전 뉴런의 출력의 효과를 가감한다. 일반적으로, 이러한 가중치는, 라벨이 붙은 대량의 입력 데이터에 네트워크를 노출하고 원하는 네트워크 출력이 달성될 때까지 시냅스들의 가중치를 점진적으로 조정하는 훈련 프로세스에서 설정된다. 그러나 실제로 이러한 대량의 라벨이 붙은 데이터는 단순히 존재하지 않을 수 있다.

[0009] 더욱이, 대규모 다층 네트워크를 모놀리식 방식으로 훈련시키는 것은, 네트워크의 여러 계층에 걸쳐 오류를 역전파해야 하기 때문에, 네트워크 크기가 그 솔루션에 연산 비용이 많이 드는 복잡한 최적화 문제를 야기하므로, 시간이 많이 걸린다.

[0010] 일반적으로 스파이킹 뉴럴 네트워크는, 오류를 결정하기 위해, 시냅스에 의해 연결된 두 뉴런의 상대적 발사 시간(firing time)에 기초한 학습 규칙에 의존한다. 일반 학습 규칙을 스파이크 타이밍 종속 가소성 또는 STDP라고 한다. 이 방법은 SNN의 잠재적으로 감독되지 않는 훈련이 시냅스의 가중치를 설정하는 것을 가능하게 하지만 본질적으로 불안정하다. 이것은 STDP가 개별 시냅스에서 가중치 조정을 목표로 하고, 네트워크 수준에서 시냅스 가중치의 균형을 맞추는 메커니즘이 없기 때문이다. 결과적으로 STDP 프로세스는 불안정할 수 있으며, 발산하는 시냅스 가중치 구성을 생성한다. 네트워크의 시냅스에 의해 형성된 흥분성 및 억제성 연결의 크기와 분포를 균형있게 조정하여 이 문제를 완화할 수 있지만, 이 프로세스는 구현하기 어렵고 안정적인 가중치 구성을 생성하기 위해 철저한 검색이 필요하다. 스파이킹 뉴럴 네트워크는 기존의 역-전파 방법으로도 훈련될 수 있다. 그러나 이러한 기술은 네트워크의 상이한 계층들에 걸친 뉴런들 간의 복잡한 인과 관계로 인해 깊은 다층 네트워크에 적용될 때 연산 비용이 많이 든다.

발명의 내용

해결하려는 과제

과제의 해결 수단

- [0011] 상기 논의된 종래 기술의 단점을 해결하기 위해, 본 개시의 일 측면에 따라, 입력 패턴 신호를 분류하기 위한 스파이킹 뉴럴 네트워크가 제안되며, 이것은 하드웨어 또는 하드웨어와 소프트웨어의 조합으로 구현된 복수의 스파이킹 뉴런과, 및 스파이킹 뉴런들을 상호연결하여 상기 네트워크를 형성하는 복수의 시냅스 요소를 포함한다. 각 시냅스 요소는 시냅스 입력 신호를 수신하고 가중치를 상기 시냅스 입력 신호에 적용하여 시냅스 출력 신호를 생성하도록 적응되며, 시냅스 요소는 각 시냅스 요소에 의해 적용되는 가중치를 조정하도록 구성될 수 있으며, 스파이킹 뉴런들 각각은 상기 시냅스 요소들의 하나 이상으로부터 시냅스 출력 신호들의 하나 이상을 수신하고, 수신된 하나 이상의 시냅스 출력 신호에 응답하여 시공간(spatio-temporal) 스파이크 열 출력 신호를 생성하도록 적응된다.
- [0012] 스파이킹 뉴럴 네트워크는 시냅스 요소들의 제1 서브-세트로부터 시냅스 출력 신호를 수신하도록 연결된 스파이킹 뉴런들의 제1 서브-세트를 포함하는 제1 서브-네트워크를 포함한다. 제1 서브-네트워크는, 시냅스 요소들의 제1 서브-세트에 적용된 서브-네트워크 입력 패턴 신호에 응답하여, 스파이킹 뉴런들의 제1 서브-세트로부터 서브-네트워크 출력 패턴 신호를 생성하도록 적응되며, 시냅스 요소들의 제1 서브-세트의 가중치는 서브-네트워크 입력 패턴 신호들의 훈련 세트에서 서브-네트워크를 훈련함으로써 구성되므로, 서브-네트워크 출력 패턴 신호는 상기 훈련 세트의 모든 고유한 서브-네트워크 입력 패턴 신호에 대해 다르다.
- [0013] 일 실시 예에서, 각각의 상이한 서브-네트워크 출력 패턴 신호 사이의 거리는 미리 결정된 임계 값보다 크고, 상기 거리는 출력 패턴 메트릭에 의해 측정된다. 스파이킹 뉴런 및 시냅스 요소는, 출력 패턴 메트릭에 의해 측정된, 두 개의 서로 다른 각각의 서브-네트워크 입력 패턴 신호에 응답하여 생성된 서브-네트워크의 두 출력 패턴 신호 사이의 각각의 거리가, 상기 훈련 세트의 모든 서브-네트워크 입력 패턴 신호에 대해 최대화되도록, 구성될 수 있다. 각각의 거리는, 출력 패턴 신호가 입력 패턴 신호의 특징들을 구별하는 데 필요한 적어도 제1 최소 감도 임계 값을 충족할 때까지, 최대화될 수 있다.
- [0014] 특징(feature)은 그 신호 및/또는 그 신호 내의 관심 패턴의 식별을 가능하게 하는 입력 패턴 신호의 임의의 특성이다. 패턴은 하나 이상의 특징으로 구성될 수 있다. 예를 들어, ECG 입력 신호의 관련 특징은 심장 박동의 상이한 스테이지(stage)를 규정하는 다양한 시변 진폭이거나, 오디오 입력 신호의 경우 관련 특징은 오디오 신호가 샘플링되는 각 불연속 시간 구간 내에서 그 신호의 주파수 콘텐츠이거나, 또는 이미지 입력 신호의 경우 관련 특징은 이미지에 있는 기본적인 모양과 선이 될 수 있다. 여기에서 추가의 예가 제공된다.
- [0015] 스파이킹 뉴럴 네트워크에서, 스파이킹 뉴런들 각각은 수신된 하나 이상의 시냅스 출력 신호에 따라 뉴런의 응답을 조정하도록 구성될 수 있다. 스파이크는 스파이킹 뉴런에 의해 하나 이상의 발사 시간에 생성될 수 있으며, 시냅스 요소들의 서브-세트 및/또는 뉴런들의 서브-세트는 두 개의 상이한 서브-네트워크 입력 패턴 신호에 대해 발사하는 뉴런들의 서브-세트의 두 세트의 발사 시간의 합집합(union)이 상기 훈련 세트의 모든 서브-네트워크 입력 패턴 신호에 대해 최소화되도록 구성될 수 있다. 각 합체는 출력 패턴 신호가 입력 패턴 신호의 특징을 구별하는 데 필요한 적어도 제2 최소 감도 임계 값을 충족할 때까지 최소화될 수 있다.
- [0016] 스파이킹 뉴럴 네트워크는 시냅스 요소들의 제2 서브-세트로부터 시냅스 출력을 수신하도록 연결된 스파이킹 뉴런들의 제2 서브-세트를 포함하는 제2 서브-네트워크를 포함할 수 있으며, 여기서 제2 서브-네트워크는 시냅스 요소들의 제2 서브-세트에 적용된 제2 서브-네트워크 입력 패턴 신호를 수신하고, 뉴런들의 제2 서브-세트로부터 대응하는 제2 서브-네트워크 출력 패턴 신호를 생성하도록 적응되며, 여기서 시냅스 요소들의 제2 서브-세트의 구성은, 제2 서브-네트워크 출력 패턴 신호가 제2 서브-네트워크 입력 패턴 신호의 모든 고유한 특징에 대해 다르도록 조정되며, 여기서 상기 네트워크는 시냅스 요소들의 제3 서브-세트로부터 시냅스 출력을 수신하도록 연결된 스파이킹 뉴런들의 제3 서브-세트를 포함하며, 여기서 제1 및 제2 서브-네트워크 출력 패턴 신호는 제3 서브-네트워크의 입력 패턴 신호이고, 여기서 시냅스 요소들의 제3 서브-세트의 구성은, 제3 서브-네트워크 출력 패턴 신호가 제1 및 제2 서브-네트워크 및 이들의 고유한 조합으로부터의 입력 패턴 신호의 모든 고유 특징에 대해 다르도록 조정된다. 따라서 제1 및 제2 서브-네트워크로부터의 입력 패턴 신호에 존재하는 특징이 제3 서브-네트워크에 의해 인코딩된다.
- [0017] 제3 서브-네트워크의 시냅스 요소는 특정 입력 패턴의 중요도에 따라 제1 및 제2 서브-네트워크로부터의 입력 패턴 신호가 가중되도록 구성될 수 있다. 네트워크는 시냅스 요소 및 스파이킹 뉴런의 서브-네트워크를 다수 포함할 수 있고, 이것에 대해 서브-네트워크 출력 패턴 신호는 서브-네트워크 입력 패턴 신호의 모든 고유한 특징에 대해 다르며, 여기서 네트워크는 네트워크에서 특정한 순차적인 순서를 가진 다수의 계층으로 분할될 수 있으며, 여기서 상기 다수의 서브-네트워크는 각각의 서브-네트워크가 속한 다수의 계층의 특정한 순차적인 순서로 인스턴스화된다.

- [0018] 스파이킹 뉴럴 네트워크에서, 시냅스 요소는 구성 가능한 스위치 행렬로서 배열될 수 있다.
- [0019] 뉴런, 시냅스 요소, 뉴런 및 시냅스 요소의 상호 연결 토폴로지 및/또는 뉴럴 네트워크의 출력 구성의 구성 정보는 구성 메모리에 저장될 수 있으며, 상기 구성 정보는 뉴럴 네트워크가 초기화 상태가 될 때 구성 메모리로부터 로딩될 수 있다.
- [0020] 한 세트의 뉴런은 하나 이상의 템플릿 뉴럴 네트워크에 배열될 수 있으며, 특정 템플릿 뉴럴 네트워크의 뉴런들은 뉴럴 네트워크의 서브-네트워크를 형성하고, 여기서 서브-네트워크 출력 패턴 신호는 서브-네트워크 입력 패턴 신호의 모든 고유한 특징에 대해 상이하며, 여기서 뉴럴 네트워크의 각 템플릿 네트워크는 미리-훈련된 방식으로 인스턴스화되었다.
- [0021] 상기 뉴럴 네트워크는 입력으로서 하나 이상의 샘플링된 입력 신호를 취하고 입력 신호를 뉴럴 네트워크 입력 패턴 신호들의 대표적인 세트로 변환하도록 구성될 수 있다. 뉴럴 네트워크의 출력 패턴 신호는 하나 이상의 출력 클래스로 분류될 수 있다.
- [0022] 본 발명의 일 측면에 따르면, 하드웨어 또는 하드웨어와 소프트웨어의 조합으로 구현된 복수의 스파이킹 뉴런들 및 스파이킹 뉴런들을 상호 연결하여 상기 네트워크를 형성하는 복수의 시냅스 요소를 포함하는 스파이킹 뉴럴 네트워크를 사용하여 입력 패턴 신호를 분류하는 방법이 제안된다. 여기서 시냅스 요소 각각은 시냅스 입력 신호를 수신하고 시냅스 입력 신호에 가중치를 적용하여 시냅스 출력 신호를 생성하도록 적용되며, 시냅스 요소는 각 시냅스에 의해 적용된 가중치를 조정하도록 구성 가능하고, 스파이킹 뉴런들 각각은 시냅스 요소들의 하나 이상으로부터 시냅스 출력 신호들의 하나 이상을 수신하고, 수신된 하나 이상의 시냅스 출력에 응답하여 시공간 스파이크 열 출력 신호를 생성하도록 적용된다. 상기 방법은: 스파이킹 뉴럴 네트워크의 제1 서브-네트워크를 정의하는 단계 - 여기서 제1 서브-네트워크는 시냅스 요소들의 제1 서브-세트로부터 시냅스 출력 신호를 수신하도록 연결된 스파이킹 뉴런들의 제1 서브-세트를 포함 -; 서브-네트워크 입력 패턴 신호의 훈련 세트에 대해 서브-네트워크를 훈련함으로써 시냅스 요소들의 제1 서브-세트의 가중치를 구성하는 단계 - 여기서 서브-네트워크 출력 패턴 신호는 상기 훈련 세트의 모든 고유한 서브-네트워크 입력 패턴 신호에 대해 상이함 -; 스파이킹 뉴럴 네트워크의 제1 서브-네트워크에 서브-네트워크 입력 패턴 신호를 적용하는 단계 - 여기서 제1 서브-네트워크는 시냅스 요소들의 제1 서브-세트로부터 시냅스 출력 신호를 수신하도록 연결된 스파이킹 뉴런들의 제1 서브-세트를 포함 -; 및 서브-네트워크 입력 패턴 신호에 응답하여 스파이킹 뉴런들의 제1 서브-세트에 의해 생성된 서브-네트워크 출력 패턴 신호를 수신하는 단계 - 여기서 출력 패턴 신호는 입력 패턴 신호의 하나 이상의 특징을 식별함 - 를 포함한다.
- [0023] 본 발명의 다른 측면에 따르면, 입력 신호에서 미리 결정된 특징을 분류하는 방법이 제안된다. 이 방법은 전술한 바와 같이 뉴럴 네트워크를 구축 및 훈련하고, 적어도 하나의 샘플링된 입력 신호를 상기 뉴럴 네트워크에 제출하고, 상기 뉴럴 네트워크의 하나 이상의 출력 클래스에서 적어도 하나의 샘플링된 입력 신호의 특징을 분류하는 것을 포함한다.
- [0024] 본 발명의 또 다른 측면에 따르면, 스파이킹 뉴럴 네트워크의 서브-네트워크 또는 그 구성에 대한 정보로서 사용하기 위한 스파이킹 뉴런들의 하나 또는 다수의 템플릿 네트워크를 포함하는 템플릿 라이브러리가 제공되며, 여기서 각 템플릿 네트워크는 한 세트의 시냅스 요소들로부터 시냅스 출력을 수신하도록 연결된 한 세트의 스파이킹 뉴런들을 포함한다. 각 템플릿 네트워크는 상기 시냅스 요소들의 세트에 적용된 템플릿 네트워크 입력 패턴 신호를 수신하고, 상기 뉴런 세트로부터 대응하는 템플릿 네트워크 출력 패턴 신호를 생성하도록 적용된다. 상기 시냅스 요소 세트의 구성은 템플릿 네트워크 입력 패턴 신호의 훈련 세트에 대해 템플릿 네트워크를 훈련 시킴으로써 조정되어, 템플릿 네트워크 출력 패턴 신호가 상기 훈련 세트의 모든 고유 템플릿 네트워크 입력 패턴 신호에 대해 상이하게 한다. 여기서 훈련 세트는 특정 작업을 수행하도록 템플릿 네트워크를 훈련시키는 데 사용되어, 각 템플릿 네트워크가 특정 작업을 수행하기 위해 사전 훈련된 방식으로 스파이킹 뉴럴 네트워크의 서브-네트워크로서 사용될 수 있도록 하거나, 스파이킹 뉴럴 네트워크의 서브-네트워크가 특정 작업을 수행하기 위해 사전 훈련된 방식으로 템플릿 네트워크의 구성에 대한 정보를 기초로 인스턴스화될 수 있게 한다.
- [0025] 본 발명의 또 다른 측면에 따르면, 스파이킹 뉴럴 네트워크를 구성하는 방법이 제안되며, 상기 방법은 전술한 바와 같이 템플릿 라이브러리로부터 하나 또는 다수의 템플릿 네트워크 또는 하나 또는 다수의 템플릿 네트워크의 구성에 대한 정보를 획득하고, 및 스파이킹 뉴럴 네트워크의 서브-네트워크가 템플릿 네트워크가 수행하도록 사전 훈련된 특정 작업을 수행할 수 있도록 스파이킹 뉴럴 네트워크의 서브-네트워크로서 상기 하나 또는 다수의 템플릿 네트워크를 인스턴스화하는 것을 포함한다.

[0026] 본 발명은 개별적으로 훈련되는 더 작은 네트워크 스테이지를 사용하여 상향식 방식으로 패턴 분류기를 실현하는 방법으로 구성된다. 패턴 분류기의 각 스테이지는, 실현되는 기능에 특유한 다른 훈련 목표와 함께 적용되는, 공통 방법론을 사용하여 특정 기능에 대해 훈련된다. 훈련 과정은 가중치를 적용할 때 시냅스의 장기 리 인과 적 영향을 설명하는 방법의 지원을 받으며, 따라서 STDP가 직면한 불안정 문제를 극복한다. 세 가지 방법은 다른 방법과 독립적으로 사용할 수 있다. 이 방법론은, 서로 다른 신호 유형에 적용할 수 있고 여러 신호에 걸쳐 패턴을 인식하여 상관시킬 수 있는 낮은 지연 패턴 인식기의 실현을 가능하게 한다. 이 방법론은 패턴 인식기의 훈련 및 배포 시간을 단순화하고, 이전에 훈련된 패턴 인식 네트워크의 재사용을 용이하게 하는 동시에, 부수적으로 구현의 유연성이 유지되는 것을 보장한다.

도면의 간단한 설명

[0027] 이제 첨부된 개략적인 도면을 참조하여 단지 예로서 실시 예를 설명할 것이며, 도면에서 대응하는 참조 부호는 대응하는 부분을 나타낸다:

도 1은 뉴런 및 시냅스 요소로 구성된 예시적인 뉴런 네트워크를 도시한다.

도 2는 데이터 변환기, 입력 인코더 및 패턴 분류기 스테이지들의 통합을 통한 패턴 인식기의 구성을 보여주며, 각 스테이지는 개별적으로 훈련되고 후속 스테이지에서 인스턴스화된다.

도 3a는 입력 인코더가 샘플링된 입력 신호를 시공간 스파이크 열로 변환하는 방법을 개략적으로 보여준다.

도 3b는 스파이크 튜플(spike tuple)의 형태로 묘사된 3개의 입력 패턴에 대한 원하는 스파이크 응답의 예를 보여줍니다.

도 4는 시냅스-후 뉴런과 후속 네트워크 계층들의 뉴런들 사이에서 깊은 인과 관계, 반-인과 관계 및 무-인과 관계를 식별하기 위한 인과 사슬(Casual Chain) STDP의 원리를 보여준다.

도 5a는 2개의 개별 스파이크 코딩된 데이터 스트림의 융합 및 융합된 스파이크 열을 사용한 후속 패턴 분류를 통한 센서-융합된 패턴 인식기의 구성을 도시한다.

도 5b는 다수의 시간 스파이크 열이 어떻게 단일의 융합된 스파이크 열로 융합되는지를 개략적으로 보여준다.

도 6은 다수의 데이터 스트림을 융합하고, 스파이킹 뉴런들의 네트워크를 사용하여, 융합된 스트림에 대해 자동 신호 인식을 수행할 수 있는 시스템을 도시한다.

도 7a는 입력 신호를 뉴런에 인터페이스 하는 방법의 예를 도시한다.

도 7b는 입력 신호를 뉴런에 인터페이스 하는 방법의 예를 도시한다.

도 8은 재설정 펄스를 생성하는 방법의 예를 도시한다.

도 9는 다수의 데이터 스트림을 융합하고, 스파이킹 뉴런들의 네트워크를 사용하여, 결과적인 융합된 스트림에 대해 자동 신호 인식을 수행하는 방법을 도시한다.

도 10은 구성 가능한 스위치 행렬을 통해 상호 연결된 뉴런과 시냅스 요소의 어레이를 도시한다.

도 11은 구성된 어레이의 예를 보여 주며, ASR 파이프 라인 스테이지의 뉴런 및 시냅스 요소에 대한 예시적인 매핑을 도시한다.

도면들은 단지 예시를 위한 것이며, 청구 범위에 의해 규정된 보호 범위의 제한으로 작용하지 않는다.

발명을 실시하기 위한 구체적인 내용

[0028] 이하, 특정 실시 예를 보다 상세히 설명한다. 그러나 이들 실시 예는 본 개시 내용에 대한 보호 범위를 제한하는 것으로 해석되지 않을 수 있음을 이해해야 한다.

[0029] 도 1은 뉴런 네트워크(100)의 단순화된 다이어그램이다. 뉴런(1)은 시냅스 요소(2)를 통해 서로 연결되어 있다. 이미지를 어지럽히지 않기 위해, 소수의 뉴런과 시냅스 요소만 표시된다(그리고 일부만 참조 부호가 붙여져 있음). 도 1 표시된 연결 토폴로지, 즉 시냅스 요소(2)가 뉴런(1)을 서로 연결하는 방식은 단지 예일 뿐이고 다른 많은 토폴로지가 사용될 수 있다. 각각의 시냅스 요소(2)는 신호를 뉴런(1)의 입력으로 전송할 수 있으며, 그 신호를 수신하는 각 뉴런(1)은 그 신호를 처리할 수 있고 후속적으로 출력을 생성할 수 있으며, 이 출력은 추가

시냅스 요소(2)를 통해 다른 뉴런(1)으로 전송된다. 각 시냅스 요소(2)는 부여된 특정 가중치를 가지며, 이 가중치는 시냅스 요소가 수신하고 전송하는 각 시냅스 입력 신호에 적용되어 가중치가 부여된 시냅스 출력 신호를 생성한다. 이와 같이 시냅스 요소의 가중치는 시냅스 요소(2)에 의해 연결된 두 뉴런(1) 사이의 인과 관계의 종류에 대한 척도이다. 상기 관계는 인과적(양의 가중치), 반-인과적(음의 가중치) 또는 무-인과적(가중치 0)일 수 있다.

[0030] 뉴런(1) 및 시냅스 요소(2)는 예를 들어 아날로그 회로 요소 또는 디지털 유선 논리 회로를 사용하여 하드웨어로 구현될 수 있다. 또한, 부분적으로는 하드웨어로 부분적으로는 소프트웨어로, 또는 전체적으로 소프트웨어로 구현될 수 있다. 빠른 처리, 예를 들어 훨씬 더 빠른 패턴 인식과, 뉴런들과 시냅스 요소들의 블록이 필요할 때만 활성화되는 이벤트-기반 처리를 달성하기 위해 하드웨어 구현이 선호된다.

[0031] 뉴런 네트워크(100)은 스파이킹 뉴런 네트워크일 수 있다. 그러면 뉴런(1)은 스파이킹 뉴런이며, 이는 하나 이상의 스파이크 형태로 뉴런 출력 신호를 생성한다. 스파이킹 뉴런(1)은 뉴런 내의 막 전위(membrane potential)(예를 들어, 에너지 전위, 또는 전압 또는 전류 레벨)가 미리 결정된 임계 값에 도달할 때만 발사(즉, 출력 스파이크를 생성)하도록 구성될 수 있다. 스파이킹 뉴런의 막 전위는 수신된 입력 신호의 결과로서 변경된다. 즉, 시냅스 요소로부터 뉴런에 의해 수신된 시냅스 출력 신호는 누적, 통합 또는 처리되어 막 전위를 변경한다. 시냅스 요소(2)의 가중치가 양수일 때, 그 시냅스 요소로부터 수신된 시냅스 출력 신호는 그 신호를 수신하는 스파이킹 뉴런(1)을 여기시켜, 그 막 전위를 높인다. 시냅스 요소(2)의 가중치가 음수일 때, 시냅스 요소로부터 수신된 시냅스 출력 신호는 그 신호를 수신하는 스파이킹 뉴런(1)을 억제하여 그 막 전위를 낮춘다. 시냅스 요소(2)의 가중치가 0일 때, 그 시냅스 요소로부터 수신된 시냅스 출력 신호는 그 신호를 수신하는 스파이킹 뉴런(1)에 어떠한 영향도 미치지 않는다.

[0032] 스파이킹 뉴런(1)의 막 전위가 임계 값에 도달하면, 뉴런이 발사하고, 발사시에 스파이크를 발생시키고, 발사의 결과로 막 전위가 감소한다. 막 전위가 후속적으로 다시 임계 값에 도달하면, 뉴런이 다시 발사하여, 두 번째 스파이크를 생성한다. 이와 같이 각각의 스파이킹 뉴런(1)은 연결된 시냅스 요소들(2)로부터 수신된 입력 신호에 응답하여 하나 이상의 스파이크를 생성하도록 구성되며, 이 스파이크들은 시공간 스파이크 열을 형성한다. 스파이킹 뉴런(1)은 막 전위가 미리 결정된 임계 값에 도달할 때만 발사하므로, 시간 정보의 코딩 및 처리가 뉴런 네트워크(100)에 통합된다. 이와 같이, 스파이킹 뉴런 네트워크(100)에서 시공간 스파이크 열이 생성되며, 이것들은 네트워크(100)의 스파이킹 뉴런(1)에 의해 생성된 스파이크들의 시간적 시퀀스이다.

[0033] 스파이크 열의 시간적 특성은 입력 신호의 진폭 및 주파수 특성을 인코딩한다. 시간적 특성은 다음을 포함한다: 자극(예를 들어 시냅스 요소로부터의 입력 신호)의 시작과 뉴런의 출력에서 스파이크의 생성 사이의 대기 시간; 동일한 뉴런에서 연속적인 스파이크들 사이의 대기 시간; 및 입력 자극이 적용되는 기간 동안 뉴런에 의해 발사된 스파이크의 개수.

[0034] 예를 들어 뉴런 네트워크(100)을 훈련시킴으로써, 시냅스 요소들의 각각의 가중치가 변경될 수 있도록, 시냅스 요소(2)가 구성될 수 있다. 뉴런(1)은 시냅스 요소의 신호에 응답하는 방식으로 구성될 수 있다. 예를 들어, 스파이크 뉴런 네트워크의 경우, 특정 신호가 막 전위, 막 전위가 자연적으로 휴지 전위를 향해 감소하는 데 걸리는 시간, 휴지 전위의 값, 스파이킹 뉴런(1)의 스파이크를 촉발하는 임계 값을 증가 또는 감소시키는 방식으로 뉴런(1)이 구성될 수 있다. 뉴런(1)의 구성은 예를 들어 훈련 동안 일정하게 유지되거나, 가변적일 수 있고 특정 훈련 세트에 대한 뉴런 네트워크(100)의 훈련에서 설정될 수 있다.

[0035] 입력 신호(11)는 예를 들어 다수의, 이중, 샘플링된 입력 신호이거나, 또는 시공간 스파이크 열이다. 상기 입력은 신호 샘플의 아날로그-디지털 변환된 값이거나, 예를 들어 아날로그 또는 디지털 적분기의 경우 샘플의 디지털 값이거나, 아날로그 적분기의 경우 샘플의 아날로그 값일 수 있다.

[0036] 뉴런 네트워크(100)의 출력 신호(12)는 예를 들어 시공간 스파이크 열이며, 이것은 출력 뉴런(1)으로부터 판독되고 출력 변환 스테이지에 의해 추가로 분류되며 사용자가 선택한 출력 코드의 유형에 대응하는 한 세트의 디지털 값들로 변환될 수 있다.

[0037] 패턴 인식과 같은 동작은 다수의 단계들(예를 들면 데이터 변환, 특징 인코딩, 분류)로 수행될 수 있다. 본 실시예는 시냅스 요소 및 뉴런(셀)의 표준화된 서브-네트워크를 사용하여 이 단계들을 실현하고, 각 애플리케이션 도메인에 대해 유연한 훈련 방법론을 사용하여 구성할 수 있게 한다. 상기 훈련 방법론의 목적은 입력 신호의 각 고유한 패턴 또는 특징에 대해 고유한 응답을 생성하도록 뉴런 네트워크의 각 스테이지 또는 서브-네트워크를 구성하는 것이다.

- [0038] 도 2는 다수의 구성 스테이지들, 이 예에서는, 데이터 변환기 스테이지(201), 입력 인코더 스테이지(202) 및 패턴 분류기 스테이지(203)의 통합에 의해 형성된 뉴럴 네트워크의 구성을 도시한다. 각 스테이지는 개별적으로 훈련되고 후속 스테이지의 훈련을 위한 네트워크에서 인스턴스화될 수 있다. 용어 "인스턴스화(instantiated)"는 서브-네트워크를 형성하는 네트워크의 일부, 예를 들어 네트워크의 한 스테이지 또는 셀이, 전형적으로 훈련에 의해, 이전에 구성되었으며, 상기 서브-네트워크의 구성 데이터가 전체 네트워크 내에서 해당 서브-네트워크를 구성하는 데 사용되는 프로세스를 지칭한다.
- [0039] 데이터 변환기 스테이지(201)는 뉴럴 네트워크에 의한 처리를 위해 입력 패턴 신호를 수신한다. 이 예에서, 데이터 변환기 스테이지(201)는 셀(301)로서 도시되고, 데이터 변환기 스테이지(202)는 셀(302)의 일부로서 도시되며, 패턴 분류기 스테이지(203)는 셀(303)의 일부로서 도시된다. 각 셀(301, 302, 303)은 셀이 구현하고자 하는 기능을 실현하는 토폴로지로 연결된, 시냅스 요소(2)의 서브-세트와 네트워크의 뉴런(1)의 서브-세트에 의해 형성된 서브-네트워크를 포함한다. 각 셀(301, 302, 303)은 매개변수화된다, 즉, 특히, 상이한 수의 시냅스 요소(2), 뉴런(1), 입력 연결, 출력 연결, 은닉 계층 연결(즉, 출력의 입력에 보이지 않는 한 계층의 뉴런들 간의 연결)을 갖도록 구성될 수 있다.
- [0040] 스테이지(201, 202, 203) 각각에서 시냅스 요소(2)의 가중치는 훈련에 의해 구성될 수 있다. 이 예에서, 데이터 변환기 스테이지(201)는 먼저 셀(301)에서 훈련된다. 데이터 변환기 스테이지(201)를 훈련한 후, 훈련된 데이터 변환기 스테이지(201) 및 셀(301)의 구성 설정이 저장될 수 있다. 이러한 저장된 설정은 그 다음에 셀(302)을 구성하는 데 사용될 수 있으며, 셀(302)은 데이터 변환기 스테이지(201) 및 입력 인코더 스테이지(203) 둘 다를 포함한다.
- [0041] 그 다음 셀(302)이 훈련될 수 있고 훈련된 인코더 스테이지(203) 및 셀(302)의 구성 설정이 저장될 수 있다. 이러한 저장된 설정은 그 다음에 셀(303)을 구성하는 데 사용될 수 있으며, 셀(303)은 데이터 변환기 스테이지(201), 입력 인코더 스테이지(203) 및 패턴 분류기 스테이지(203)를 포함한다. 그런 다음 셀(303)이 훈련될 수 있고 훈련된 패턴 분류기 스테이지(203) 및 셀(303)의 결과적인 구성 설정이 저장될 수 있다.
- [0042] 상기 훈련은 고유한 응답 알고리즘을 사용하여 수행될 수 있다. 고유한 응답 알고리즘은 각 세포의 시냅스 요소의 가중치의 구성을 실현하여, 결과적으로 입력 신호의 고유한 특징을 세포 뉴런(1)의 고유한 응답으로 트랜스 코딩 한다. 스파이킹 뉴런의 경우 이것은 고유한 스파이킹 응답일 수 있다. 고유한 응답 알고리즘은 아래에 자세히 설명되어 있다. 셀 응답의 고유성은 입력 패턴 신호(11)의 구별되는 특징을 셀의 별개의 출력 신호(12A, 12B, 12C)로 분리하는 셀의 능력을 나타낸다. 스파이킹 뉴런의 경우에서, 이러한 별개의 출력 신호(12A, 12B, 12C)는 별개의 출력 스파이크 열, 예를 들면, 셀의 출력 뉴런들로부터의 고유한 시공간 스파이크 열 출력 세트일 수 있다. 시공간 스파이크 열 출력 세트의 고유성은 셀의 각 출력 뉴런에 의해 생성된 스파이크의 개수 및/또는 스파이크들의 타이밍에 의해 결정될 수 있다. 결과적으로, 네트워크 훈련 중에, 각 응답의 고유성은 네트워크에 입력이 제공되고 스파이크로 변환된 후 테스트 되며, 각 셀(301, 302, 303)의 출력 응답(12A, 12B, 12C)이 고유성 기준을 충족할 때까지, 훈련되는 셀의 시냅스 요소의 가중치는 고유한 응답 방법론을 사용하여 적응된다. 교사 입력(teacher input)(13A, 13B, 13C)은, 후술하는 바와 같이, 각 셀(301, 302, 303)에 대해 원하는 고유 응답을 얻기 위해 사용될 수 있다.
- [0043] 고수준 기능을 실현하기 위해, 이전에 훈련된 셀들(301, 302, 303)은 상향 방식으로 인스턴스화되고 상호연결된다. 즉, 가장 낮은 수준 셀(301)이 먼저 훈련된 다음, 후속 스테이지(202)를 포함하는 더 높은 수준(302)에서 인스턴스화된다. 그 다음에 중간 수준 셀(302)이 후속 스테이지(203)를 포함하는 더 높은 수준 셀(303)에서 인스턴스화된다. 더 높은 수준 셀의 각 생성에 이어서, 고유한 응답 알고리즘이 호출된다.
- [0044] 셀(301, 302, 303)은 상이한 애플리케이션 도메인의 특정 기능과, 다른 네트워크에서 재사용할 수 있는 템플릿 라이브러리에 저장된 훈련된 셀의 구성 설정에 대해 이러한 방식으로 훈련될 수 있다. 예를 들어, 구어 인식 네트워크의 입력 인코더 스테이지(202)는 어떤 변경 없이 핫-워드(hot-word) 트리거링 네트워크에서 재사용될 수 있다. 이러한 재사용은 전체 훈련 시간과 복잡성을 줄이는 데 도움이 된다.
- [0045] 도 3a는 입력 인코더(22)가 샘플링된 입력 신호(20)를 어떻게 시공간 스파이크 열(24)로 변환하는지 개략적으로 도시한다. 입력 인코더(22)의 각 출력 뉴런은 시간 스파이크 열인 출력 신호(23)를 형성한다. 입력 인코더(22)는 예를 들어 입력 인코더의 시냅스 요소의 가중치가 설정되는 구성(21)에 의해 구성된다.
- [0046] 도 3b는 스파이킹 뉴럴 네트워크의 셀에 대한 3개의 상이한 입력 패턴에 대해 3개의 원하는 스파이크 응답(14A, 14B, 14C)의 예를 도시한다. 이 예의 각 응답은 셀의 출력 뉴런(N1, N2, N3, N4, N5)에 의해 생성된 한 세트의

하나 이상의 시공간 스파이크 열의 형태를 취한다. 각각의 응답(14A, 14B, 14C)은 각각의 네트워크에 대해 선택될 수 있는 개별 시간 빈(bin)(15A, 15B, 15C)에 대해 설명된다. 시간 빈(15A, 15B, 15C)은 적어도 셀에 대한 첫 번째 입력 자극의 시작과 해당 셀의 출력 뉴런으로부터의 마지막 응답 사이의 시간만큼 클 수 있다. 상기 시간 빈은 셀의 미완성 대기 시간의 배수일 수 있으며, 이 배수는 입력 자극의 결과로서 셀의 출력 뉴런 당 생성되는 전형적인 스파이크 개수와 같다.

[0047] 상기 고유한 응답 방법론의 각각의 호출 동안, 셀(301, 302, 303)은 처리될 입력 패턴으로부터 유도된 입력 데이터(11)에 노출될 수 있다. 입력 데이터(11)는 처리를 위해 뉴럴 네트워크에 제공되는 입력 패턴(p)으로부터 유도된다.

[0048] 입력 패턴(p)은 예를 들어 음성 인식 애플리케이션을 위한 오디오 신호, 이미지 인식 애플리케이션을 위한 정지 이미지 또는 비디오 이미지, 또는 패턴 인식 시스템에 적합한 다른 많은 유형의 패턴을 포함할 수 있다. 입력 데이터(11)는 다음을 포함할 수 있다: 단일 항목의 시변 데이터(예를 들어, 오디오 신호 예를 들어 마이크에 의해 출력되는 아날로그 또는 디지털 신호에서 유도된 단일 스트림의 데이터), 여러 항목의 데이터(예를 들면 CCD 어레이에 의해 출력된 정지 이미지의 개별 픽셀을 나타내는 한 세트의 입력 데이터), 여러 항목의 시변 데이터(예를 들면, 비디오 이미지의 개별 픽셀을 나타내는 한 세트의 입력 데이터 스트림), 또는 단일 항목의 데이터에서 생성된 여러 증강된 버전(예를 들어, 입력 신호들의 조합).

[0049] 셀(301, 302, 303)의 시냅스 요소(2)의 가중치는, 시냅스 가중치를 조정할 때 장거리 인과 관계를 설명하는 학습 규칙인 인과 사슬 스파이크-타이밍-종속 가소성(CC-STDP: Causal Chain Spike-timing-dependent plasticity)을 사용하여 적용될 수 있다. 이러한 의미에서 이것은, 가중치를 적용할 때 단거리 인과관계만 설명하여, 일부 훈련 세트를 사용한 가중치의 갱신을 상당히 불안정하고 혼란스럽게 하고 대부분 국부적인 행동의 결과를 생성하는 기존의 스파이크-타이밍-종속 가소성(STDP)과 상이하다. CC-STDP는 아래에 추가로 제공된다. 일단 셀이 훈련되면, 훈련된 셀에 대한 구성 설정이 템플릿 셀들의 라이브러리에 저장되고 나중에 다시 호출되어 재사용될 수 있다.

[0050] 각 입력 패턴(p)에 대해 원하는 스파이크 응답(14A, 14B, 14C)은, 입력 패턴(p)으로부터 유도된 입력 데이터(11)가 제공되는 각 시간 빈에서 스파이크 응답을 지정하는 튜플로서 설명될 수 있다. 예를 들어, 상기 튜플은 입력 데이터(11)에 대한 응답으로 발사된 셀의 출력 뉴런들(A^p)의 개체군(population)과 그것들의 정확한 발사 시간(B^p)을 지정할 수 있다. 응답의 고유성은, 일반적으로 A^p 및 B^p 의 함수인 거리 함수 또는 메트릭(예를 들면 빅터 푸르푸라(Victor Purpura) 또는 반 로섬(Van Rossum) 거리 함수)을 사용하여 다른 입력 패턴에 대한 셀의 응답에서 거리를 계산하여 결정된다.

[0051] 바람직한 실시 예에서, 각 입력 패턴(p)에 대해 세트(A^p)는 단일 출력 뉴런(1)을 포함하는 분리 세트를 설명할 수 있고, 세트(B^p)는 출력 뉴런(1)이 응답할 때에 대응하는 시간 빈을 설명할 수 있다. 따라서, 이 실시 예에서, 각각의 입력 패턴(p)은 가장 먼저 응답하는 단일 뉴런(1)에 의해 식별될 수 있다. 예를 들어 동일하거나 다른 뉴런의 이후 응답은 승자 독식 네트워크를 사용하여 억제되거나 무시될 수 있다. 추가 견고성을 위해, 상기 튜플은 뉴런의 응답 강도(입력 데이터(11)가 적용되었던 기간에 단일 초기 스파이킹 뉴런에 의해 생성된 스파이크 이벤트의 수로 표현됨, C^p)를 설명하는 추가 필드(C^p)로 증가될 수 있다.

[0052] 대안적인 실시 예에서, 각 패턴(p)에 대해, 세트 A^p 는 다수의 출력 뉴런(1)을 포함하는 분리 세트일 수 있고, 세트 B^p 는 이러한 뉴런의 응답 시간을 포함하는 동일한 크기의 세트일 수 있다. 아래 제시된 인과 사슬 STDP 규칙을 사용하여 원하는 스파이크 튜플에 도달하기 위해, 셀의 응답은 다른 A^p 및 B^p 값을 향해 조정될 수 있다.

[0053] B^p 값은 해당 뉴런(1)의 발사에 기여하는 시냅스 요소의 가중치를 증가시킴으로써 감소될 수 있는 반면, B^p 값은 이러한 가중치를 감소시킴으로써 증가될 수 있다. 이는 출력 뉴런(1)의 인과적 발사를 인위적으로 촉진함으로써, 또는 입력 데이터(11)의 적용에 수반되는 초기 스파이크를 유도하여 인과적 발사를 촉진함으로써 달성할 수 있다. 이것은 기여하는 경로의 양 또는 음의 시냅스 가중치 조정을 초래한다.

[0054] 도 3b에서, 원하는 스파이크 응답(14A, 14B, 14C)이 3개의 입력 패턴(p)에 대해 도시된다. 제1 입력 패턴의 응답은 제1 시간 빈(15A) 동안 생성되었고, 제2 패턴의 응답은 제2 시간 빈(15B) 동안 생성되었고, 제3 패턴의 응답은 제3 시간 빈(15C) 동안 생성되었다. 제1 패턴(p_1)은 튜플 $A^{p_1} = \{N3\}$, $B^{p_1} = \{3\}$ 및 $C^{p_1} = \{1\}$ 을 가진다. 제

1 패턴(p_2)은 튜플 $A^{p_2} = \{N1, N2, N4\}$, $B^{p_2} = \{2, 4, 5\}$ 및 $C^{p_2} = \{1, 1, 1\}$ 을 가진다. 마지막으로 제3 패턴(p_3)은 튜플 $A^{p_3} = \{N2, N3, N5\}$, $B^{p_3} = \{2, \{2, 3, 4\}, 4\}$ 를 갖고, $C^{p_3} = \{1, 3, 1\}$.

- [0055] 상기 고유한 응답 방법의 목적은 각 고유 입력 패턴에 대해 고유한 시공간 스파이크 열 세트를 생성하는 것이다. 이러한 시공간 스파이크 열은 정밀하게 시간이 지정된 전기 펄스들의 시퀀스로 구성될 수 있다. 응답의 고유성은 다음과 같이 설명할 수 있다.
- [0056] 출력 스파이크 열을 생성하는 뉴런 세트를 A 라고 하자. 주어진 알려진 입력 패턴을 p 라고 하자. A 의 서브-세트인 A^p 는 주어진 입력 패턴(p)에 대해 발사하는 뉴런들의 세트를 나타낸다. $A_s = \{A^p | p \in P\}$ 는 알려진 모든 입력 패턴의 세트(P)의 각 입력 패턴(p)에 대해 발사하는 모든 뉴런들의 세트를 나타낸다.
- [0057] 또한, 특정 입력 패턴(p)에 대해 F_i^p 를 뉴런(i)의 정확한 발사 시간들의 세트라고 하자. $B^p = \{F_1^p, F_2^p, \dots, F_{NO}^p\}$ 를 특정 입력 패턴(p)에 대한 모든 출력 뉴런($1, 2, \dots, NO$)의 정확한 발사 시간들의 세트라고 하자. $B_s = \{B^p | p \in P\}$ 는 알려진 모든 입력 패턴(P) 세트의 모든 입력 패턴(p)에 대한 정확한 발사 시간들을 포함하는 세트들의 세트를 나타낸다.
- [0058] 일 실시 예에서, 예를 들어 시변 입력의 각각의 주어진 샘플링 창 내에서, 다음 규칙 중 하나 이상이 적용되는 경우, 입력 데이터(11)에 대한 네트워크의 응답은 고유하다고 부를 수 있다. 제1 규칙으로, P 의 모든 고유 입력 패턴(p, q)(따라서 $p \neq q$)에 대해, $\Delta(A^p, A^q) \neq 0$ 을 유지해야 한다. 제2 규칙으로, P 의 모든 고유 입력 패턴(p, q)에 대해, $\Delta(B^p, B^q) \neq 0$ 을 유지해야 한다.
- [0059] 거리 $\Delta(A^p, A^q)$ 및 $\Delta(B^p, B^q)$ 는 빅터 푸르푸라, 반 로섬, ISI, 또는 SPIKE-거리 등과 같은 적절한 스파이크 거리 메트릭 $\Delta(\cdot, \cdot)$ 을 사용하여 함께 계산될 수 있다.
- [0060] 이러한 규칙은 시냅스 가중치 구성을 위한 목표로서 적용할 수 있으며, 다음과 같이 다시 설명할 수 있다. 제1 가중치 구성 목표는 A_s 의 모든 A^p 에 대해 A_s 의 각 A^q 에 대해 거리 $\Delta(A^p, A^q)$ 를 최대화하는 것일 수 있다. 여기서 q 는 P 의 다른 특정 입력 패턴이다. 제2 가중치 구성 목표는 B_s 의 모든 B^p 에 대해 B_s 의 각 B^q 에 대한 거리 $\Delta(B^p, B^q)$ 가 최대화되고 B_s 의 각 B^q 에 대한 합집합 $B^p \cup B^q$ 가 최소화되는 것일 수 있다. 여기서 q 는 P 의 다른 특정 입력 패턴이다.
- [0061] 이러한 가중치 구성 목표를 기반으로 원하는 스파이크 튜플이 생성될 수 있고, 예를 들어 입력 인코더 스테이지(202)는 아래에 제시된 바와 같이 CC-STDP를 사용하여 훈련될 수 있다. 이 연습의 목적은 후속 스테이지가 입력 패턴의 특징을 구별하는 데 사용할 수 있는 고유 응답을 생성하는 입력 인코더 단계(202)의 구성에 도달하는 것이다.
- [0062] 상기 구성 목표는 최적을 산출하기 위한 것이지만, 연산 비용이 많이 들 수 있다. 더 간단한 접근 방식은, 입력 인코더 스테이지의 출력이 후속 처리 스테이지에서 특징을 구별하는 데 필요한 최소 감도 임계 값을 적어도 충족하는 시점까지, $\Delta(A^p, A^q)$, $\Delta(B^p, B^q)$ 가 증가하고 $B^p \cup B^q$ 가 감소하도록 목표를 제한하는 것이다. 이를 통해 인코딩의 견고성과 품질에 영향을 주지 않으면서 가중치 구성 훈련 프로세스의 실행 시간을 줄일 수 있다.
- [0063] 일단 관심 있는 모든 패턴에 대해 스파이크 튜플들의 전체 세트가 설명되거나 생성되면, 셀(301, 302, 303)에서 뉴런(1) 연결의 시냅스 요소(2)의 가중치는, 제시된 입력 패턴에 대해 원하는 고유 반응을 나타내도록 훈련될 수 있다. 지도 학습 방식에서, 이 훈련은 지도 방식(예를 들어 자동 인코더 방식, 철저한 검색, 경사 하강법, 역-전파 사용 등)을 사용하여 수행된다. 그러나 이것은 연산 비용이 많이 든다. 다음에는, 새로운 STDP 가중치 촉진 계획에 의존하는 반-지도(semi-supervised)(교육 방법론을 설명한다. 반-지도는 결과 오류가 무엇인지 말하지 않지만, 예를 들어 특정 입력 패턴에 대해 고유 응답을 얻기 위해 원하는 또는 필요한 스파이크가 무엇인지를 의미할 수 있다.
- [0064] 기존의 STDP에서, 시냅스 요소의 가중치 변화는 특정 시냅스 요소(2)에 의해 서로 연결된 두 뉴런(1)의 상대적인 발사 시간에 따라 달라진다. 그러나 결과적인 가중치 변화는 주로 국부적인 행동의 결과이다. CC-STDP는 대

신 시냅스-전 뉴런의 더 긴 인과 사슬에 대한 가중치 변화를 예측한다. 즉, 발사 이벤트가 네트워크의 후속 계층에서 뉴런의 발사에 기여하는 경우에만 가중치가 조정된다.

[0065] 도 4는 CC-STDP 학습 규칙의 원리를 보여주며, 가중치가 $w_{1,2}$ 인 특정 시냅스 요소(2)의 시냅스-전 뉴런(N1) 및 시냅스-후 뉴런(N2)과 네트워크의 후속 계층들의 뉴런(N3, N4, N5) 사이의 깊은 인과 관계, 반-인과 관계 및 무-인과 관계를 식별할 수 있다.

[0066] CC-STDP 규칙은 특정 출력 스파이크 응답을 얻기 위해 셀의 반-지도 훈련에 적용될 수 있다. 예를 들어, 특정 시간($t_{spike\ n}$)에 스파이크가 필요한 특정 출력 뉴런을 n 이라고 가정한다. 훈련하는 동안, 뉴런(n)에서 시간($t_{spike\ n}$)에 인위적으로 스파이크를 유도함으로써, 네트워크의 초기 계층에 있는 뉴런과 뉴런(n) 사이의 관계 특성이 설정될 수 있다. 이러한 관계는 인과적(초기 계층의 뉴런이 출력 뉴런에서 스파이크를 유발함), 반-인과적(초기 계층의 뉴런이 출력 뉴런에서 스파이크를 일으키지 않지만 두 뉴런은 발사시 동기화되며, 출력 뉴런 이후 초기 뉴런이 발사함), 또는 무-인과적(두 뉴런은 발사 행동에 어떤 동기화도 없음). 따라서 CC-STDP는 네트워크의 이전 계층에 있는 뉴런과 원하는 출력 뉴런 사이의 인과 관계를 식별할 수 있으며, 이 인과 경로에 개재하는 시냅스 요소의 가중치를 조정할 수 있다.

[0067] 스파이크가 바람직하지 않을 수 있는 뉴런에서, 셀에 입력 샘플의 제시와 수반하여, 즉 동일한 시간 구간에서, 스파이크를 유도함으로써 반-인과 관계가 모방될 수 있다. 이것은 출력 뉴런이 모든 이전 계층의 뉴런보다 먼저 발사하게 하여, 반-인과 관계를 생성하고, 차례로 이 경로를 따라 개재하는 시냅스 요소의 국부적인 침체(depression)를 유발할 수 있다.

[0068] 따라서, 특정 시간($t_{spike\ k}$)에 원하는 출력 뉴런에서 그리고 입력 자극의 적용과 동시에 다른 뉴런에서 스파이크를 유도함으로써, 네트워크는 원하는 스파이킹 응답 패턴으로 응답하도록 구성된다.

[0069] 뉴런(i)과 뉴런(j) 사이에 위치한 시냅스 요소의 가중치($w_{i,j}$)는 예를 들어 다음 규칙에 따라 변경될 수 있다:

$$\Delta w_{i,j} = \begin{cases} \delta w_{i,j} & \delta w_{i,j} > 0 \text{에 대해 } w_{j,k} \neq 0 \text{이고 } t_{spike\ k} > t_{spike\ j} \text{이고 } t_{spike\ k} > t_{spike\ i} \text{이면} \\ \delta w_{i,j} & \delta w_{i,j} < 0 \text{에 대해} \\ 0 & w_{j,k} = 0 \text{ 또는 } t_{spike\ k} \leq t_{spike\ i} \text{ 또는 } t_{spike\ k} \leq t_{spike\ j} \text{ 또는 } t_{spike\ k} = 0 \text{이면} \end{cases} \quad (1)$$

[0070]

[0071] 식(1)에서, $\Delta w_{i,j}$ 는 뉴런(i)과 뉴런(j) 사이의 시냅스 요소에 대한 유효 가중치 변화이고, $w_{j,k}$ 는 후속 계층의 뉴런(j)과 뉴런(k) 사이의 시냅스 요소의 가중치이다. $t_{spike\ i}$, $t_{spike\ j}$ 및 $t_{spike\ k}$ 는 뉴런 i , j 및 k 가 각각 스파이크하는 정확한 시간을 나타낸다. $\delta w_{i,j}$ 는 상대적 스파이킹 시간으로 인한 뉴런(i)과 뉴런(j) 사이의 시냅스 요소의 가중치 변화이고, STDP 학습 규칙을 사용하여 계산할 수 있다.

[0072] 따라서, 식(1)의 학습 규칙에 따르면, 뉴런 i 와 j 사이의 시냅스 요소의 가중치 변화가 양수여야 하고, 뉴런 i 와 k 사이의 가중치가 0이 아니고, 뉴런 k 가 두 뉴런 i 와 j 보다 나중에 스파이크하면, $\Delta w_{i,j} = \delta w_{i,j}$ 이다. 뉴런 i 와 j 사이의 시냅스 요소의 가중치 변화가 음수여야 한다면 $\Delta w_{i,j} = \delta w_{i,j}$ 이다. 마지막으로, 뉴런 k 가 스파이크하지 않거나, 뉴런 k 가 즉시 스파이크하거나, 또는 뉴런 k 가 뉴런 i 또는 j 보다 먼저 스파이크하거나, 또는 뉴런 j 와 k 사이의 가중치가 0인 경우, 가중치 변화는 0이 된다. 후자의 경우, 뉴런 i 발사와 뉴런 k 발사 사이에 인과 관계가 없는 것으로 보인다.

[0073] 대체 학습 규칙이 사용될 수도 있으며, 이 경우 위 방정식의 스파이크 시간 매개 변수는 선택한 학습 규칙의 기본 매개 변수(예를 들면 스파이크 속도)로 대체될 수 있다.

[0074] 이 원리는 도 4를 참조하여 설명할 수 있다. 예를 들어, 특정 출력 뉴런에서 특정 시간에 스파이크가 유도된다(예를 들면, 뉴런 N3에서 스파이크 시간 $t_{spike\ N3} = 4\text{ms}$ 에, 뉴런 N4에서 스파이크 시간 $t_{spike\ N4} = 3\text{ms}$ 에, 뉴런 N5에서 유도된 스파이크 없음). 이런 식으로, 원하는 특정 시공간 스파이크 출력 패턴이 만들어진다. 이 원하는 출력 패턴은 스파이킹 뉴런 네트워크의 특정 시공간 입력 패턴(예를 들면 $t_{spike\ N1} = 1\text{ms}$ 에서 발사하는 뉴런 N1)에 속한다. 예를 들어, 이 입력 패턴과 특정 시냅스 가중치($w_{1,2}$)로 인해, 뉴런 N2는 $t_{spike\ N2} = 3\text{ms}$ 에서 발사한다. 시냅스 요소 $\Delta w_{1,2}$ 에 대한 유효 가중치 변화는 예를 들어 위의 식(1)을 사용하여 계산할 수 있다. $w_{2,3} \neq 0$ 이므로, $w_{1,2} > 0$ 이면 이 특정 시간에 발사되는 뉴런 N3의 기여도는 $\delta w_{1,2}$ 이다. $w_{2,4} = 0$ 이므로, 시냅스 가중치에 대한 뉴런 N4 발사로부터의 결과적인 변화는 0이다. 뉴런 N5는 스파이크하지 않기 때문에 뉴런 N5로부터

의 결과적인 변화는 0이다.

- [0075] 스파이킹 뉴럴 네트워크를 훈련시키기 위해 CC-STDP가 사용되는 실시 예에서, 특정 시간에 특정 뉴런(1)에서 스파이크 생성을 유도 및/또는 억제 가능할 수 있어야 한다. 예를 들어, 이것은 다음과 같은 방법으로 수행될 수 있다(이 목록은 전체 목록이 아님). 스파이크를 유도하기 위한 한 가지 방법은, 바이어스 전압 입력을 통해 해당 뉴런의 막을 발사 임계 값을 초과하는 전압까지 구동하여, 스파이크 생성을 유도하는 것이다. 또 다른 방법은, 원하는 시간에 뉴런의 출력에 인공 스파이크를 주입하는 것이다. 스파이크를 방지하기 위한 한 가지 방법은, 해당 뉴런의 막을 무반응 전압(refractory volatge) 또는 가능한 가장 낮은 전압까지 구동하여, 스파이크 생성을 방지하는 것이다. 대안으로, 예를 들어 적분기에서 뉴런 입력을 분리함으로써, 이에 따라 예를 들어 출력에서 스파이크 생성회로를 분리하여, 뉴런에서 스파이크 생성을 비활성화할 수 있다. 뉴런에서 스파이크 생성을 유도하거나 비활성화하기 위한 이러한 신호는 교사 입력(13A, 13B, 13C)으로 설명되며, 이는 각 셀(301, 302, 303)에 대해 원하는 고유 응답을 얻는 데 사용될 수 있다.
- [0076] 도 5a는 2개의 개별 데이터 스트림(11A, 11B)의 융합을 통한 센서-융합된 패턴 인식기의 구성과, 패턴 분류기 스테이지(204)에서 융합된 스트림(12C)을 사용하는 후속 패턴 분류를 도시한다. 패턴 분류기 스테이지(204)의 출력(12D)은 예를 들어 패턴 분류기 스테이지(204)의 출력 뉴런에 의해 생성된 시공간 스파이크 열 세트(12D)가 될 수 있으며, 여기서 세트(12D)의 각 스파이크 열은 패턴 분류기 스테이지(204)에서 단일의 특정 출력 뉴런에 의해 생성된다.
- [0077] 즉, 한 계층이 한 스테이지(예를 들어, 융합 시스템에서 입력 인코더 스테이지를 형성하는 다수 입력 인코더(202A, 202B)에 다수의 동시 셀을 갖는 경우, 이들 셀(202A, 202B) 각각은 후속 스테이지(203)를 갖는 셀에서 인스턴스화 되기 전에 먼저 구성될 수 있다. 네트워크의 모든 스테이지는 교사 입력(13A1, 13A2, 13B1, 13B2, 13C, 13D)를 사용하여 훈련될 수 있다. 모든 동시 셀이 동일한 데이터에 대해 동일한 기능을 수행하는 경우(예를 들어 레이더 트랜시버의 상이한 수신기 안테나들의, 또는 상이한 방향을 가리키는 상이한 마이크의 입력 인코딩), 각 인스턴스에 대해 별도의 훈련 시퀀스를 실행할 필요가 없을 수도 있다. 오히려, 단일의 훈련된 셀이 여러 번 인스턴스화 될 수 있다. 결과적으로, 훈련된 셀 또는 그 구성은 다른 스파이킹 뉴럴 네트워크에서 구현되어 동일한 기능을 수행할 수 있다. 따라서, 스파이킹 뉴럴 네트워크를 구성하는 동안, 동일한 기능이 필요한 경우 어떤 새로운 훈련의 필요 없이, 이미 훈련된 셀이 구현될 수 있다. 따라서 스파이킹 뉴럴 네트워크의 구성은 시간이 덜 걸리고 덜 복잡할 것이다.
- [0078] 훈련된 셀의 템플릿 라이브러리로서 사용되도록 메모리 장치를 구성할 수 있다. 그러한 메모리 장치에는, 스파이킹 뉴럴 네트워크의 하나 이상의 훈련된 셀의 소프트웨어 및/또는 하드웨어 설정이 저장될 수 있다. 그러한 셀의 시냅스 요소(2)의 구성 설정은 예를 들어 시냅스 요소들의 각각의 가중치일 수 있다. 이러한 셀의 뉴런(1)의 구성 설정은 예를 들어 뉴런의 발사 임계 값, 누출률, 휴지 값, 무반응 수준(refractory level), 무반응 기간(refractory period), 또는 다른 매개 변수일 수 있다.
- [0079] 각 셀은 특정 기능을 수행하도록 훈련된다. 특정 스파이킹 뉴럴 네트워크에서 특정 기능을 가진 그런 새로운 셀이 필요한 경우, 그 셀은 처음부터 훈련할 필요가 없으므로, 시간을 절약하고 스파이킹 뉴럴 네트워크를 훨씬 더 효율적으로 구현할 수 있다. 대신, 해당 기능을 위해 설계된 사전 훈련된 셀의 구성 설정은 템플릿 라이브러리로서 구성된 메모리 장치에서 가져올 수 있다. 사전 훈련된 셀 구성 설정을 사용하여 새로운 셀을 인스턴스화 하면, 상기 새로운 셀이 상기 사전 훈련된 셀과 동일한 방식으로 기능을 할 것이다.
- [0080] 상기 메모리 장치는 임의의 컴퓨터 판독 가능 저장 매체일 수 있다. 메모리 장치는 비일시적 저장 매체일 수 있다. 예시적인 컴퓨터 판독 가능 저장 매체는 다음을 포함하지만 이에 제한되지는 않는다: (i) 정보가 영구적으로 저장될 수 있는 쓰기 불가능한 저장 매체(예를 들어, CD-ROM 드라이브에 의해 판독 가능한 CD-ROM 디스크, ROM 칩 또는 임의의 유형의 솔리드-스테이트 비휘발성 반도체 메모리와 같은 컴퓨터 내 읽기 전용 메모리 장치); 및 (ii) 변경 가능한 정보가 저장될 수 있는 쓰기 가능한 저장 매체, 예를 들어 하드 디스크 드라이브 또는 임의의 유형의 솔리드-스테이트 랜덤 액세스 반도체 메모리, 플래시 메모리.
- [0081] 상기 템플릿 라이브러리는 또한 각각 특정 기능을 수행하도록 사전 훈련된 하드웨어 스파이킹 뉴럴 네트워크 셀의 모음일 수도 있다. 이러한 하드웨어 셀은 그런 특정 기능을 가진 셀이 필요한 스파이킹 뉴럴 네트워크에서 직접 사용될 수 있다.
- [0082] 도 5a에서, 2개의 데이터 변환기 스테이지(201A, 201B)는 셀(301A, 301B)에서 각각 입력 패턴 신호(11A, 11B)로 훈련되어 스파이크 응답 출력(12A1, 12AB)을 생성할 수 있다. 셀(301A, 301B)의 구성은 셀(302A, 302B)에서

저장되고 인스턴스화될 수 있으며, 셀(302A, 302B)에는 각각 후속 스테이지, 즉 입력 인코더 스테이지(202A, 202B)가 포함된다. 셀(302A, 302B)은 각각 입력 패턴 신호(11A, 11B)로 훈련될 수 있으며, 그 결과 데이터 변환기 스테이지(201A, 201B)의 출력(12A1, 12B1)이 입력 인코더 스테이지(202A, 202B)에 대한 입력 데이터가 된다. 셀(302A, 302B)의 구성이 셀(303)에서 마찬가지로 저장되고 인스턴스화될 수 있으며, 셀(303)에는 후속 스테이지, 즉 데이터 융합 스테이지(203)가 포함된다. 셀(303)은 두 입력 패턴 신호(11A, 11B)를 사용하여 훈련될 수 있으며, 그 결과 입력 인코더 스테이지(202A, 202B)의 출력(12A2, 12B2)이 데이터 융합 스테이지(203)에 대한 입력 데이터가 된다. 입력 인코더 스테이지(202A, 202B)의 출력(12A2, 12B2)의 시공간 스파이크 열은 데이터 융합 스테이지(203)의 하나 이상의 뉴런(1)에서 후속적으로 동시에 일어난다. 데이터 융합 스테이지(203)의 출력(12C)은 시간 스파이크 열(데이터 융합 스테이지(203)가 하나의 출력 뉴런(1)만 포함하는 경우)이거나, 또는 다수의 스파이크 열(입력 인코더 스테이지(202A, 202B)로부터의 출력(12A2 및 12B2)에 의해 합동-자극에 응답으로 생성된 시공간 스파이크 열 세트(데이터 융합 스테이지(203)가 다수의 뉴런을 포함하는 경우)이다. 결과적인 스파이크 열의 융합된 세트(12C)는 융합된 모든 입력 패턴 신호(11A, 11B)의 특징 공간의 조합을 나타낸다. 결과적으로, 융합된 스파이크 열은 현재 시간 창에서 입력 패턴 신호에 존재하는 모든 특징을 인코딩한다.

[0083] 예를 들어, 입력 패턴(11A, 11B)의 특징 e 및 f 를 각각 포함하는 두 세트의 입력 스파이크 열(12A2, 12B2)을 융합할 때, 결과적인 융합된 스파이크 열(12C)은 특징 e 및 f 모두의 대응하는 고유 표현을 포함한다. 데이터 융합 스테이지(203)를 구성하는 목적은 상기 융합된 출력 신호(12C)의 특징 부분-공간에 대해 각각의 입력 패턴 신호(11A, 11B)의 완전한 특징 공간의 이러한 고유 매핑을 달성하는 것이다.

[0084] 각각의 입력 패턴 신호 M_α 및 M_β 의 특징을 인코딩하고 두 세트의 스파이크 열 P_α 및 P_β 를 생성하는 두 개의 입력 인코더 α 및 β 를 고려한다.

[0085] 인코딩하고자 하는 신호 M_α 에서 u 개의 알려진 특징들의 세트는 $\Phi(\alpha) = \{\phi_1, \phi_2, \dots, \phi_u\}$ 로 주어지며, 이것은 따라서 신호 M_α 의 특징 공간이 된다. $A_\alpha = \{A_1, A_2, \dots, A_u\}$ 는 특징 ϕ_i 에 대해 발사하는 출력 뉴런 A_i 의 세트들의 세트이다. u 개의 알려진 특징들 모두에 대한 뉴런의 정확한 발사 시간을 포함하는 세트들의 세트는 $B_\alpha = \{B_1, B_2, \dots, B_u\}$ 이며, 여기서 B_α 의 각 B_i 는 특징 ϕ_i 에 대한 출력 뉴런의 정확한 발사 시간 세트이다.

[0086] 데이터 융합이 무손실이 되려면, 융합 스파이크 열 $\Phi(\gamma)$ 의 특징 공간이 서로 다른 입력 신호의 개별 특징 공간을 포함할 수 있다:

[0087]
$$\Phi(\gamma) = \Phi(\alpha) \cdot \Phi(\beta) + \Phi(\alpha) + \Phi(\beta). \quad (2)$$

[0088] 특성 공간 $\Phi(\gamma)$ 에 대응하는 시공간 스파이크 열은 입력 인코딩에 대해 명시된 대로 규칙 1 및 2를 준수할 수 있다. 즉, 후속 처리 스테이지가 스파이크 코딩된 특징들 사이를 구별할 수 있도록 충분한 고유성을 가질 수 있다. 따라서, 스파이크 튜플의 생성은 위에서 설명한 고유 응답 방법론을 사용할 수 있으며, 입력 스파이크 열의 각 고유한 특징 조합은 융합 블록에서 고유한 출력 시공간 스파이크 열 세트를 생성한다.

[0089] 도 5b는 작업 예에서 다수의 시간 스파이크 열(30A, 30B)이 단일의 융합된 스파이크 열(35)로 어떻게 융합되는지를 개략적으로 도시한다. 시간 스파이크 열(30A, 30B)은 각각 시냅스 요소(31A, 31B)를 통해 전송되고 뉴런(34)으로 향한다. 뉴런(34)은 하나 이상의 시냅스 요소(33)를 통해 뉴런(34)에 연결된 재귀 연결(recurrent connection)(32)을 가질 수 있다. 융합된 스파이크 열(35)은 제1 시간 스파이크 열(temporal spike train)(30A) 및 제2 시간 스파이크 열(30B) 둘 다의 특징 공간의 조합을 나타낸다. 후속 처리 스테이지는, 융합된 스파이크 열(35)에서 이들 특징의 표현이 충분히 독특하기 때문에, 제1 시간 스파이크 열(30A)과 제2 시간 스파이크 열(30B)의 스파이크 인코딩된 특징을 구별할 수 있다.

[0090] 데이터 융합을 사용하는 신호 인식 시스템에서, 데이터 소스는 최종 결과에 미치는 영향에 따라 중요도가 달라질 수 있다. 특정 기능은 신호 인식 프로세스의 기본적인 수 있지만, 다른 기능은 인식 결과의 품질을 향상시키는 역할만 한다. 결과적으로, A_α 와 A_β 의 융합된 특징 공간을 나타내는 스파이크 열의 세트인 A_γ 의 크기는 덜 중요한 특징의 효과를 줄임으로써 크기를 줄일 수 있다. 이것은 적어도 세 가지 방법으로 수행될 수 있다.

- [0091] 첫째, 특정 입력 스파이크 열의 덜 중요한 특징에 수반하여, 데이터 융합 스테이지(203)의 출력 뉴런에 인과적 스파이크를 도입함으로써 수행된다. 이 방법은 입력 패턴에 원하는 특징이 없는 경우에 적용할 수 있다.
- [0092] 둘째, 융합 프로세스에서 각각의 우선 순위에 대응하여, 각각의 입력 인코더 스테이지(202A, 202B)로부터 출력을 수신하는 데이터 융합 스테이지(203)의 입력 시냅스 요소에 가중치 편향을 도입함으로써, 덜 원하는 특징이 또한 억제될 수 있다. 결과적으로, 입력 인코더 스테이지(202A, 202B)로부터의 스파이크 열은, 이들이 융합되기 전에, 데이터 융합 스테이지(203)의 출력에 대한 원하는 영향에 따라, 가중치가 부여될 수 있다. 이것은 입력 신호와 결과적인 융합된 표현 사이의 에너지 전달 제어를 용이하게 한다. 신호에 대한 우선순위 편향을 높이면 해당 신호가 융합된 표현에 미치는 영향을 높일 수 있다. 신호의 편향을 최대화하면 융합된 표현이 입력 신호를 복제시킨다. 반대로, 신호에 대한 우선순위 편향 가중치를 최소화하면 융합된 표현에 대한 영향을 줄일 수 있는 반면, 가중치를 완전히 무효화하면 융합된 결과에 대한 신호의 영향을 완전히 제거한다. 융합 동안, 공간 스파이크 분포 A_α 및 A_β 는 데이터 융합 스테이지(203)의 구성에 의해 실현되는 전달 함수(f)를 통해 융합된 공간 분포 A_γ 로 변환된다. 따라서, 우선순위 편향된(biased) 실시 예에서, 융합된 분포는 다음과 같은 형태를 취한다:
- [0093]
$$A_\gamma = f\left((A_\alpha, w_\alpha), (A_\beta, w_\beta)\right) \text{ 그리고 } B_\gamma = f\left((B_\alpha, w_\alpha), (B_\beta, w_\beta)\right). \quad (3)$$
- [0094] 식(3)에서, w_α 및 w_β 는 데이터 융합 단계(203)에서 스파이크 열 세트 P_α 및 P_β 의 영향을 제어하는 우선순위 바이어스 가중치 세트이다.
- [0095] 가장 간단한 세 번째 방법은 어떤 특징도 억제하거나 축소하지 않는 것이며, 대신 융합된 표현에 그 영향을 포함하는 것이다. 이 특징에 대응하는 표현은 단순히 후속 분류 스테이지(204)에서 무시될 수 있다. 즉 관심이 없는 클래스가 할당될 수 있다. 이 접근 방식은 원하지 않는 특징 조합을 명확하게 분류하여 원하는 특징의 더욱 정확한 식별을 가능하게 하므로 정확도를 증가에 기여한다.
- [0096] 다음으로, 융합 및 패턴 인식 시스템에서 위의 원리를 적용하는 것을 설명한다.
- [0097] 도 6은 마이크로프로세서 또는 하드웨어 로직 시스템(600)과 인터페이스된 스파이킹 뉴런 네트워크(400)에 기초한, 데이터 융합 및 자동 신호인식을 위한 시스템(700)의 일 실시 예의 단순화된 블록도이다.
- [0098] 스파이킹 뉴런 네트워크(400)는 하나 또는 다수의 입력 인코더 스테이지($401_1, \dots, 401_N$); 입력 인코더 스테이지($401_1, \dots, 401_N$) 각각은 구성 데이터(717)에 의해 구성 가능하다. 입력 인코더 스테이지($401_1, \dots, 401_N$)는 입력 패턴 신호($711_1, \dots, 711_N$)를 수신하고 이러한 입력 패턴 신호를 시공간 스파이크 열($P_1, \dots, P_N$)로 변환하고 각 입력 패턴 신호($711_1, \dots, 711_N$)의 특징 공간을 인코딩한다. 입력 패턴 신호 세트($711_1, \dots, 711_N$)는 예를 들어 입력 패턴 데이터를 샘플링하여 신호들의 세트를 생성함으로써 도출될 수 있다. 예를 들면, CCD 어레이 이미지 센서를 사용하여 이미지를 기록하여 이미지 센서의 하나 이상의 픽셀에 의해 기록된 이미지 데이터를 각각 나타내는 일련의 입력 패턴 신호($711_1, \dots, 711_N$)의 세트를 생성한다.
- [0099] 각각의 스파이크 열($P_1, \dots, P_N$)은 각각의 입력 패턴 신호($711_1, \dots, 711_N$)에 응답하여 입력 인코더 스테이지($401_1, \dots, 401_N$)의 하나 이상의 뉴런에 의해 생성된, 정확한 시간이 지정된 전압 스파이크의 시퀀스를 포함할 수 있다.
- [0100] 단일 입력 패턴 신호($711_1, \dots, 711_N$)를 인코딩하기 위해 다수의 뉴런이 사용되는 경우, 다수의 뉴런들 각각의 출력은 위에서 언급한 시간적 특성 중 하나 이상을 갖는 하나 이상의 스파이크를 포함하는 스파이크 열일 수 있다. 입력 인코더 단계($401_1, \dots, 401_N$)의 출력 뉴런에 의해 생성된 통합된 스파이크 열($P_1, \dots, P_N$)은 상기 제공된 입력 패턴 신호($711_1, \dots, 711_N$)에 대한 인코딩된 시공간 스파이크 응답을 함께 나타낸다.
- [0101] 도 7a는 뉴런(1)이 시냅스 요소(2)의 출력 신호와 같은 입력 신호(801)와 어떻게 인터페이스 되는지를 보여준다. 뉴런(1)은 뉴런(1)이 입력 신호(1)에 반응하는 방식을 변경하는 특정 구성을 가지며, 여기서 뉴런 구성은 구성 신호(CN)를 사용하여 설정된다. 입력 신호(801) 및 상기 뉴런 구성에 따라, 뉴런(1)은 특정 시공간 스파이크 열(S)을 출력할 것이다. 도 7b에서, 입력 신호(802)는 각각 특정 방식으로 구성된 다수의 시냅스 요소

(2A, 2B)로부터의 시냅스 출력 신호의 조합이며, 여기서 각 시냅스 요소의 구성은 구성 신호(C_{SB} , C_{SB})를 사용하여 설정될 수 있다. 시냅스 요소(2_A , 2_B)는 입력으로서 입력 신호(803) 또는 다른 뉴런(804)으로부터의 재귀 입력을 가질 수 있다.

[0102] 각 뉴런(1)은 해당 뉴런(1)의 정확한 발사 행동을 제어하는 구성 매개 변수(C) 세트를 가질 수 있다. 예를 들어, 뉴런은 발사 임계 값으로 설계될 수 있으며, 이것은 입력을 수신하는 결과로서 뉴런에서 누적되는 전압, 에너지 또는 기타 변수의 임계 값을 나타내며, 여기서 뉴런은 누적된 변수가 상기 발사 임계 값을 충족하거나 초과할 때 출력 스파이크(예를 들어 전압, 전류 또는 에너지 스파이크)를 생성한다. 뉴런은 누적된 변수에 대해 조정을 결정하기 위해 뉴런에 입력을 통합하는 통합 기능을 구현할 수 있다. 또한, 뉴런은 다음을 갖도록 설계될 수도 있다: (a) 뉴런에 누적된 변수가 시간이 지남에 따라 감소하는 비율을 나타내는 누출률; (b) 뉴런에 대해 입력 신호가 없을 때 누적된 변수가 시간이 지남에 따라 감소하는 값을 나타내는, 누적된 변수의 휴지 값; (c) 뉴런에서 누적된 변수의 증가 또는 감소를 결정하기 위해 입력 신호가 통합되는 시간을 나타내는 통합 시간 상수; (d) 뉴런의 발사 직후 뉴런의 누적된 변수의 값을 나타내는 무반응 수준; (e) 뉴런의 누적 변수가 뉴런의 발사 후 휴지 값으로 상승하는 데 필요한 시간을 나타내는 무반응 기간. 이러한 매개 변수들은 각 뉴런에 대해 미리 결정되고 및/또는 구성 가능하고 및/또는 조정 가능할 수 있다. 예를 들어 중요한 입력 신호 특징의 에너지 함량과 일치하도록 뉴런의 발사 임계 값, 누출 속도, 통합 시간 상수, 및 무반응 기간을 조정함으로써, 뉴런(1)은 그 특징을 포함하는 입력 신호로 자극될 때 하나 이상의 정확히 시간 지정된 스파이크를 생성한다.

[0103] 다시 도 6을 참조하면, 각각의 입력 인코더 스테이지($401_1, \dots, 401_N$)는 다수의 스파이킹 뉴런(1)을 포함할 수 있다. 입력 인코더 스테이지($401_1, \dots, 401_N$)에 대한 입력은 아날로그 또는 디지털 값(예를 들어, 입력 패턴 데이터의 아날로그-디지털 변환된 값)일 수 있다. 디지털 적분기가 있는 뉴런을 사용할 때, 뉴런에 대한 각 입력 신호의 디지털 값은 뉴런의 적분기에 직접 입력으로 제공된다. 입력 신호의 비트 너비(B_s)와 적분기의 비트 너비(B_i)는 다음과 같은 예시적인 방법들 중 하나 또는 조합에 의해 매칭된다.

[0104] 첫 번째 방법으로, 디지털 입력의 후행($B_s - B_i$) 비트는 $B_s > B_i$ 일 때 폐기된다. 두 번째 방법으로, $B_i > B_s$ 일 때 디지털 입력에 ($B_i - B_s$) 후행 '0' 비트가 패딩된다. 세 번째 방법으로, 디지털 입력에 B_n 후행 '0' 비트가 패딩되거나, B_n 후행 비트가 폐기된다. 여기서 B_n 은 디지털 입력의 진폭이 멤브레인의 전압 범위 내에서 시프트되는 것을 허용하는 구성 가능한 매개 변수가 될 수 있다. 이 시프트는 입력 신호와 적분기 비트 폭이 일치할 때도 샘플 값의 패딩 및 자르기 조합을 사용하여 역시 실현할 수 있다.

[0105] 아날로그 적분기가 있는 뉴런(1)을 사용할 때, 디지털 값은 B_s 시냅스 요소(2)에 대한 시냅스-전 입력으로 제공될 수 있으며, 시냅스-후 출력 단자는 입력 인코더 스테이지($401_1, \dots, 401_N$)의 뉴런(1)에 연결된다. 디지털 뉴런에 대해 이전에 설명한 바와 같이, 진폭 시프팅은 입력 신호 벡터(비트 열로 구성됨)를 B_n 비트로 패딩 및/또는 절단하여 실현할 수 있다. 다른 실시 예에서, 입력 신호의 아날로그 값은 아날로그 적분기에 대한 입력으로서 직접 제공될 수 있다. 예를 들어 적분기가 전하를 축적하도록 하기 위해, 아날로그 값이 일정 기간 동안 적분기에 제공될 수 있다. 적절한 임계 전압을 선택하면, 뉴런의 정확한 발사 시간이 아날로그 입력 신호 값의 진폭에 반비례하여 변할 수 있다(즉, 진폭이 높을수록 뉴런이 더 빨리 발사됨). 또한, 적절하게 선택된 민감도 임계 값을 가진 다수 뉴런(1)을 활용함으로써, 복잡한 다중-레벨 아날로그-스�파이크 변환기를 실현할 수 있다.

[0106] 이러한 실시 예에서, 입력 패턴 신호($711_1, \dots, 711_N$)의 제시된 아날로그 전압 값을 고유한 등가 스파이크 표현으로 변환하는 데이터 변환기 스테이지($201_1, \dots, 201_N$)가 포함될 수 있으며, 여기서 입력 값들 사이의 거리와 출력 스파이크 응답들 사이의 대응하는 거리는 비례한다. 입력 인코더 스테이지($401_1^1, \dots, 401_N$)는 데이터 컨버터 스테이지($201_1, \dots, 201_N$)로부터의 트랜스코딩된 스파이크 응답에서 식별된 특징을 고유한 표현으로 인코딩한다.

[0107] 시스템(700)에 공급된 입력 패턴 신호($711_1, \dots, 711_N$)는 변화하는 동적 범위를 가질 수 있다: 일부는 낮고 일부는 높을 수 있다. 절대적인 동적 범위는 그 자체로 중요하지 않을 수 있지만, 다른 진폭들의 특징들 사이를 구별하는 능력은 중요할 수 있다. 따라서 입력 인코더 스테이지($401_1, \dots, 401_N$)의 구성이 모든 알려진 관심 있는 특징을, 어느 진폭에서 발생하든, 고유한 스파이크 표현으로 인코딩되도록 보장하는 것이 필요할 수 있다. 즉, 의도는 관심 범위의 하나 이상의 진폭에서 고유한 스파이크 특성을 얻는 것이다.

[0108] 따라서, 입력 인코더 스테이지($401_1, \dots, 401_N$)는 임의의 수의 입력을 연결하고 입력 패턴 신호($711_1, \dots, 711_N$)에

존재하는 특징을 인코딩하는 임의의 수의 스파이크 열 출력($P_1, \dots, P_N$)을 생성하는 뉴런(1)의 그룹을 포함할 수 있다. 여기서 입력 신호 ($711_1, \dots, 711_N$)는 예를 들어 입력 패턴 신호의 단일 샘플링된 데이터 포인트로서 또는 입력 패턴 신호의 공간적인 또는 시간적인 또는 시공간적인 일련의 샘플링된 데이터 포인트로서 정의될 수 있다.

- [0109] 입력 패턴 신호에서 검출될 특징 또는 패턴은 예를 들어 단일 샘플링된 입력 데이터 포인트 또는 샘플링된 입력 데이터 포인트 세트의 특정 콘텐츠, 예를 들면, 특정 시점에서 입력 신호의 진폭, 이진 이미지 프레임의 특정 위치에서 "ON" 픽셀의 존재, 특정 시점에서 특정 입력 신호 속성의 강도.
- [0110] 검출될 특징 또는 패턴은 또한 입력 신호를 형성하는 일련의 샘플링된 데이터 포인트들에서 콘텐츠의 공간적 시퀀스에 있을 수 있다, 예를 들어 이진 이미지에서 개체의 가장자리에 해당하는 "ON" 픽셀.
- [0111] 검출될 특징 또는 패턴은 또한 입력 신호를 형성하는 단일 데이터 포인트의 여러 샘플에 걸친 콘텐츠의 시간적 시퀀스에 있거나, 또는 샘플링된 데이터 포인트들의 여러 공간적 시퀀스에 걸친 콘텐츠의 시간적 시퀀스에 있을 수도 있다. 예를 들어, 입력 신호의 삼각파 패턴을 규정하는, 진폭의 하강 시퀀스가 이어지는 진폭의 상승 시퀀스, 또는 시간에 따른 개체의 움직임에 대응한, 입력 신호를 형성하는 비디오 이미지의 여러 프레임에 걸친 개체 가장자리의 변위.
- [0112] 다시 도 6에 도시된 실시 예를 참조하면, 입력 인코더 스테이지($401_1, \dots, 401_N$)에 의해 생성된 스파이크 열 출력($P_1, \dots, P_N$)은 먼저 위에서 설명한 바와 같이 우선순위 편향 모듈(402)의 우선순위 편향 계획에 따라 선택적으로 가중치가 부여된 다음, 도 6에 도시한 데이터 융합 스테이지(403)에서 융합된다. 결과적인 시공간 스파이크 열(712)은 그 다음 시공간 스파이크 열(712)을 분류하는 분류기 스테이지(404)에 의해 수신된다. 분류기 스테이지(404)는 트랜스코딩된 표현에 존재하는 가장 강한 시공간 패턴을 식별할 수 있고 이것을 예를 들어 특정 출력 뉴런과 연관시킬 수 있다.
- [0113] 분류기의 입력은, 예를 들어 한 세트의 입력 신호($711_1, \dots, 711_N$)만 있는 시스템의 경우 입력 인코더 스테이지로부터의 한 세트의 스파이크 열($P_1, \dots, P_N$)이거나, 또는 인코딩된 후 대표적인 스파이크 열(712) 세트로 융합되는 다수 세트의 입력 신호($711_1, \dots, 711_N$)를 갖는 시스템의 경우, 데이터 융합 스테이지(403)로부터의 한 세트의 열(712)일 수 있다. 도 6에서 분류기 스테이지(404)는 데이터 융합 스테이지(403)로부터 그 입력(712)을 획득한다.
- [0114] 분류기의 출력(713)은 출력 포트(R) 상의 분류된 시공간 스파이크 열(713)의 세트일 수 있으며, 여기서 각 스파이크 열(713)은 분류기(404)의 단일 특정 출력 뉴런에 의해, 또는 다수의 출력 뉴런에 의해 생성될 수 있다. 상기 고유 응답 원리를 준수하는 분류기 실시 예에서, 스파이크는 각각의 고유한 입력 특징 또는 입력 패턴 신호들의 고유한 입력 특징 조합에 대해 별도의 출력 뉴런에 의해 생성될 수 있다. 이 실시 예에서, 각각의 관심 패턴에 대한 스파이크 튜플은 적어도 하나의 스파이크로 특정 시간 구간으로 스파이크하는 단일 뉴런(즉, A^p 는 패턴 p 에 대한 단위 세트임)으로 구성된다. 따라서 출력 포트는 관심 있는 패턴만큼 많은 스파이크 열을 포함할 수 있다.
- [0115] 앞서 설명한 가중치 구성 목표의 관점에서 이를 다시 설명하면, 알려진 입력 패턴에 대한 응답으로 출력 스파이크 열(713)을 생성하는 분류기의 출력 뉴런의 일반 세트를 A 라 하고, 주어진 알려진 입력 패턴(p)에 대해 발사하는 뉴런을 포함하는 A 의 서브-세트를 A^p 라 하고, $A_s = \{A^p | p \in P\}$ 를 알려진 입력 패턴(P) 세트의 모든 p 에 대해 모든 A^p 의 슈퍼-세트라고 하면, 위의 내용이 유지되는 분류기 스테이지(404)에 대해: A_s 의 각 A^p 는 단위 세트일 것이고, P 의 각 q 에 대해 $p \neq q$ 인 경우 $A^p \neq A^q$ 를 유지한다. 다음으로, 도 6에 도시된 바와 같이, 출력 변환 스테이지(501)를 포함하는 논리 유닛(500)은 분류기 스테이지(404)로부터의 출력(713)(예를 들어, 시공간 스파이크 열의 세트(713))을 예를 들어 사전(601)으로부터 저장 및 검색될 수 있는 디지털 코드(714)로 변환할 수 있다.
- [0116] 따라서 분류기 스테이지(404)의 출력은 시공간 스파이크 열(713)의 세트일 수 있으며, 여기서 하나 이상의 특정 스파이크 열(713)은 특정 특성을 나타내므로, 예를 들어 입력 패턴($711_1, \dots, 711_N$)이 특정 클래스 또는 라벨에 속하는 것으로 식별되도록 허용한다. 출력 변환 스테이지(501)는 스파이크 열 특성을 사전(601)으로부터 저장 및 검색될 수 있는 디지털 코드(714)로 변환함으로써 이러한 식별 프로세스를 용이하게 할 수 있다.

- [0117] 스파이크 열의 특징 정보는 예를 들면 다음과 같은 여러 형태로 인코딩될 수 있다: 입력 자극이 제시된 경과 시간 동안에 분류기 스테이지(404)의 출력 뉴런(1)이 발사되는 개체군 코드(population code); 입력 자극이 제시된 이후 특정 기간 내에 분류기 스테이지(404)의 출력 뉴런(1)이 먼저 발사한 개체군 시간 코드(population temporal code); 입력 자극이 제시된 경과 시간 동안에 분류기(404)의 출력 뉴런(1)에 의해 생성된 스파이크 수를 설명하는 개체군 속도 코드(population rate code); 분류기 스테이지(404)의 특정 출력 뉴런(1)이 발사된 정확한 시간을 설명하는 시간 코드(temporal code); 그리고 마지막으로 분류기 스테이지(404)의 특정 출력 뉴런(1)의 발사 속도를 설명하는 속도 코드.
- [0118] 공간적 및 시간적 스파이킹 정보의 조합은 순전히 공간적인 분류기(404) 출력보다 훨씬 더 상세히 제공할 수 있다. 예를 들어, 입력 패턴 신호($711_1, \dots, 711_N$)가 두 개의 지배적인 특징 X와 Y를 포함하고 그 중 하나는 다른 것보다 더 강하다고 가정해 보자. 두 특징의 상대적인 강도는 그들 각각의 분류 스테이지 출력(713)의 발사 속도를 측정하여 결정될 수 있다. 대안으로, 더 강한 특징은 해당 출력 뉴런(1)의 시간 코드를 기반으로, 특히 어느 출력 뉴런(1)이 더 빨리 발사했는지를 결정하여 식별될 수 있다.
- [0119] 출력 변환 스테이지(501)는 분류기의 출력 포트 상의 스파이크 활동을 분석하기 위한 회로를 포함할 수 있다. 회로는 예를 들어 사용자 구성(717)에 따라, 사용자가 어레이의 뉴런의 스파이킹 행동에 대해 수행하고자 하는 분석 유형을 기반으로 활성화된다: 스파이킹 개체군, 정확한 스파이크 타이밍, 발사 속도 및 이들의 조합.
- [0120] 코드 유형 개체군을 위해, 변환 방법은 입력 패턴 신호를 적용한 후 뉴런이 현재시간 구간에서 스파이크했는지를 표시하기 위해 분류기 스테이지(404)의 출력 뉴런 당 하나의 레지스터를 갖는 것으로 구성된다. 코드 유형 개체군 시간을 위해, 변환 방법은 입력 패턴 신호를 적용한 후 현재시간 구간에서 어느 뉴런이 먼저 스파이크했는지를 표시하기 위해 분류기 스테이지(404)의 출력 뉴런 당 하나의 레지스터를 갖는 것으로 구성된다. 가장 빠른 스파이크 이벤트가 등록된 후, 다른 레지스터는 비활성화된다. 코드 유형 개체군 속도를 위해, 변환 방법은 입력 패턴 신호를 적용한 후 현재시간 구간에서 출력 뉴런에 의해 생성된 스파이크의 수를 계산하기 위해 분류기 스테이지(404)의 출력 뉴런 당 카운터를 갖는 것으로 구성된다. 0이 아닌 스파이크 카운트 값이 있는 카운터는 또한 개체군 코드를 표시한다. 코드 유형 시간을 위해, 변환 방법은 출력 뉴런이 스파이크할 때까지 입력 패턴 신호를 적용한 이후 경과된 시간을 정확하게 측정하기 위해 분류기 스테이지(404)의 출력 뉴런 당 시간-디지털 변환기를 갖는 것으로 구성된다. 마지막으로, 코드 유형 속도를 위해, 변환 방법은 입력 패턴 신호를 적용한 후 현재시간 구간에서 출력 뉴런에 의해 생성된 스파이크의 수를 계산하기 위해 분류기 스테이지(404)의 출력 뉴런 당 카운터를 갖는 것으로 구성된다.
- [0121] 출력 변환 스테이지(501)에 대한 입력은 분류기 스테이지(404)의 모든 출력 뉴런(1)로부터의 스파이크들의 벡터(713)일 수 있고, 회로(501)의 출력(714)은 사용자가 선택한 출력 코드의 유형에 대응하는 한 세트의 디지털 값일 수 있다. 출력 변환 스테이지(501)에 대한 입력(713)은 신호 샘플이 유효한 시간 창 의 기간에 제공될 수 있다. 출력 변환 스테이지(501)로부터의 출력(714)은 상기 시간 창 의 끝에서 유효할 수 있고, 다음 시간 창이 시작되기 전에 재설정될 수 있다. 분류 출력(713)은 단일 해시 코드, 또는 입력 패턴 신호(들)($711_1, \dots, 711_N$)의 패턴들의 고유한 지문으로 사용될 수 있는 해시 코드들의 세트로 변환될 수 있다.
- [0122] 다음으로, 도 6을 다시 살펴보면, 해시 테이블 또는 사전 조회 기능(601)을 포함하는 마이크로프로세서 또는 논리 회로(600)는 디지털 코드(714)를 취하고, 후속적으로, 인식된 특징에 대응하는 사용자 공간 식별자를 결정하기 위해 해시 테이블 또는 사전 조회 동작이 수행될 수 있다.
- [0123] 이 동작은 분류기 스테이지(404)의 출력을 사용자 공간, 즉 입력 패턴의 사용자 정의된 식별자로 디코딩하는 것을 허용한다. 상기 구성 단계 동안, 패턴 인식기(400)는 샘플 특징 및 패턴으로 훈련될 수 있고, 상기 생성된 해시 코드는 기록될 수 있다. 예를 들어, 상기 생성된 해시 코드와 함께 해시 테이블 또는 사전(601)에 저장될 수 있는 사용자 정의된 식별자가 샘플 패턴에 할당될 수 있다. 실행 시, 인식기(400)가 신호의 특징을 인식하는데 사용되는 경우, 상기 생성된 해시 코드는 상기 인식된 특징에 대응하는 사용자 공간 식별자를 결정하기 위해 해시 테이블 또는 사전 조회 작업에서 사용된다.
- [0124] 도 6에 도시된 재설정 생성기 및 시퀀서(718)는, 예를 들어 새로운 샘플링 창 의 시작에서, 데이터 융합 스테이지(403), 분류기 스테이지(404) 및 출력 변환 스테이지(501)의 내용을 재설정할 수 있다. 이 동작은 네트워크(400)로부터 잔여 스파이크를 제거하고, 이전 창 의 영향 없이 다음 샘플링 창이 평가될 수 있도록 한다.
- [0125] 상기 샘플링 창은 창 크기와 동일한 깊이의 입력 버퍼로 구현될 수 있다. 대안으로, 네트워크에서 스파이크 행동을 저지하고 출력 스테이지를 재설정하는 주기적 재설정 신호를 사용하여 구성 가능한 가상 샘플링 창이 실현

될 수 있다. 이러한 방법의 샘플링 창은 재설정 신호와 동일한 주기를 가질 수 있다. 상기 샘플링 창을 구성할 때, 기간은 가장 긴 알려진 기능을 완전히 수용할 수 있을 만큼 충분히 길어야 하지만, 각 창의 특징 내용이 최소화되어 특징 인식의 정확도가 높아질 수 있도록 충분히 작아야 한다. 샘플링 창의 폭은 시스템(700)이 검출할 수 있는 특징의 입도에 영향을 미칠 수 있다. 일반적으로 샘플링 창 지속 시간은, 나이퀴스트(Nyquist) 속도보다 크거나 같은 샘플링 속도로, 입력 신호에 특징이 표시되는 시간척도보다 커야한다고 말할 수 있다. 여러 입력 인코더 스테이지($401_1, \dots, 401_N$) 또는 단일 입력 인코더 스테이지($401_1, \dots, 401_N$)를 사용하여 상이한 시간척도에서의 특징이 검출될 수 있다. 샘플링 창의 길이는 또한 출력 변환 스테이지(501)에서 사용되는 카운터의 폭에 영향을 미칠 수 있다.

[0126] 도 8은 재설정 펄스 생성의 예를 나타낸다. 클럭 정보(904)는 업-카운터(up-counter)(901)의 값을 변경한다. 샘플링 주기(905)에 대한 정보와 함께, 업-카운터(901)의 값과 비교기(902)에 제출된다. 비교기(902)는 업-카운터(901) 값이 여전히 샘플링 주기(905) 내에 존재하는지 확인한다. 그렇지 않은 경우, 비교기(902)는 펄스 발생기(903)에 신호를 전송하고, 펄스 발생기(903)는 재설정 신호(906)를 도 6 신호(716))로서 업-카운터(901)와 시스템(700) 내의 각각의 모듈에 보낸다.

[0127] 마찬가지로, 재설정 신호의 경우, 두 개의 연속 재설정 펄스 사이의 기간은 예를 들어 다음 공식을 따를 수 있다:

$$t_{reset} \geq \max(t_{feature}) + \max(t_{fallthrough}) + t_{output} + \max(t_{lookup}). \quad (4)$$

[0129] 식(4)에서 $t_{feature}$ 는 특징의 지속 시간이고, $t_{fallthrough}$ 는 스파이크 열이 입력 인코더 스테이지로부터 분류기 스테이지의 출력까지 전파되기 위한 미완성 대기 시간이고, t_{output} 은 하나의 해시 또는 해시들의 세트를 생성하기 위한 출력 변환 스테이지의 대기 시간이며, t_{lookup} 은 해시 테이블/사전 조회 작업에 대한 최악의 대기 시간이다.

[0130] 상기 재설정 펄스의 지속 시간은 적절한 구성 요소들의 재설정 회로를 트리거링 하기에 충분해야 한다. 재설정 중에, 네트워크(400)의 모든 뉴런(1)의 상태가 재설정된다. 즉, 예를 들어 막 전압이 휴지 상태로 돌아오고, 인터페이스 신호들이 자신의 초기화된 상태(즉, 시스템이 프로그래밍된 후의 상태)로 재설정된다. 시냅스 판독 회로가 재설정되고(가중치는 유지됨), 진행중인 시냅스 갱신이 중단된다. 출력 스테이지(500)에서, 뉴런(1)의 개체군 및 발사 속도를 추적하는 카운터 및 레지스터도 재설정될 수 있다. 재설정은 입력 인코더 스테이지($401_1, \dots, 401_N$)에 영향을 주지 않으므로, 샘플링 창들 사이의 전환 중에도 입력 패턴 신호($711_1, \dots, 711_N$)를 스파이크로 연속 인코딩하는 것을 보장할 수 있다.

[0131] 도 9는 다수의 이중 입력 패턴 신호를 단일의 대표적인 스파이크 열 세트에 융합하고, 이어서 이 스파이크 열에 대해 자동 신호인식을 수행하여 패턴/특징을 검출하고 식별하는 방법(1000)을 예시한다. 방법(1000)은 시작점(1000S)에서 시작한다.

[0132] 제1 단계(1001)에서, 새로운 신호 샘플은 하나 또는 다수의 입력 인코더 스테이지($401_1, \dots, 401_N$)에 의해 시공간 스파이크 열로 인코딩된다. 하나 또는 다수 출력 인코더의 출력은 시공간 스파이크 열($P_1, \dots, P_N$)이다.

[0133] 제2 단계(1002)에서, 스파이크 열($P_1, \dots, P_N$)은 우선순위 편향에 의해 융합에서의 중요성에 따라 가중치가 부여된다. 우선순위 편향 모듈(402)의 출력은 가중치가 부여된 이중 시공간 스파이크 열이다.

[0134] 제3 단계(1003)에서, 상기 이중 시공간 스파이크 열은 데이터 융합 스테이지(403)에 의해 개별 특징 부분-공간들(sub-spaces)을 포함하는 대표적인 스파이크 열 세트(712)로 통합된다. 데이터 융합 스테이지의 출력은 융합된 시공간 스파이크 열(712)이다.

[0135] 제4 단계(1004)에서, 분류기 스테이지(404)는 융합-후 스파이크 열(712)에서 공간, 시간 및 속도 특징을 분류한다. 따라서 시간 스파이크 열이 분류된다..

[0136] 제5 단계(1005)에서, 출력 변환 스테이지(501)는 상기 분류된 스파이크 열(713)을 분류 코드(714)로 변환한다.

[0137] 제6 단계(1006)에서, 상기 방법은 새로운 샘플링 창이 시작될 때까지 기다릴 수 있다.

[0138] 제7 단계에서, 분류 코드(714)에 대응하는 패턴 식별자(700)의 해시 테이블 또는 사전(601)에서 조회 및 출력이 수행된다.

- [0139] 마지막으로, 제8 단계(1008)에서, 데이터 융합 스테이지(403), 분류기 스테이지(404) 및 출력 변환 스테이지(501)가 재설정된다.
- [0140] 이 방법은 다시 제1 단계 1001에서 시작하여 반복될 수 있다.
- [0141] 일반적으로, 여기에 설명된 시스템 및 방법은 고유한 자극에 응답하여 고유한 시공간 스파이크 열을 생성하는 수단으로서 스파이킹 뉴런(1)의 네트워크를 사용하며, 여기서 응답의 고유성은 스파이킹 뉴런(1) 및 상호 연결 네트워크의 작동 매개 변수를 통해 제어할 수 있다. 상기 시스템은 구성 가능한 매개 변수를 가진 시냅스 요소(2)를 통해 상호 연결된, 구성 가능한 매개 변수를 가진 스파이킹 뉴런들(1)의 어레이로 구성된다. 상기 어레이를 다수의 다른 네트워크로 가상 분할함으로써, 상기 시스템은 여러 기능을 동시에 실현할 수 있다.
- [0142] 예를 들어, 하나의 네트워크는 다수의 이중 샘플링된 입력 신호를, 입력 신호의 특징 공간을 완전히 인코딩하는 대표적인 시공간 스파이크 열 세트에 변환할 수도 있다.
- [0143] 제2 구성에서, 본 발명은 다수의 이중 샘플링된 입력 신호를, 모든 입력 신호의 개별 특징 공간들의 수퍼세트인 특징 공간을 갖는 대표적인 단일의 시공간 스파이크 열 세트에, 변환할 수도 있다.
- [0144] 제3 구성에서, 본 발명은 네트워크 고유성의 적절한 구성을 통해 시공간 스파이크 열을 하나 이상의 출력 클래스로 분류할 수도 있다.
- [0145] 본 발명의 뉴런, 시냅스 요소 및 상호 연결 네트워크의 구성 가능성은 동일한 어레이의 개별 뉴런 그룹들에 대해 서로 다른 조합으로 세 가지 구성 모두의 동시 실현을 용이하게 한다. 시냅스 요소는 구성 가능한 스위치 행렬로서 역할을 한다.
- [0146] 일 실시 예에 따른 스파이킹 뉴런 네트워크(1100)가 도 10에 도시된다. 여기서, 뉴런($N_0, \dots, N_7$)은 구성 가능한 스위치(1103)를 통해 구성 가능한 시냅스 요소(2)의 어레이(1102)로 구성된 구성 가능한 스위치 행렬을 통해 상호 연결된, 뉴런(1101)의 어레이에 배열된다.
- [0147] 입력 신호(1104)는 시냅스 요소(2)의 가중치에 따라 시냅스 요소(1102)의 어레이를 통해 뉴런($N_0, \dots, N_7$)으로 전송될 수 있다. 또한, 두 개의 뉴런($N_0, \dots, N_7$)은, 시냅스 요소(2)의 가중치 및 구성 가능한 스위치(1103)의 연결 토폴로지에 따라, 시냅스 요소(1102)의 어레이 및 구성 가능한 스위치(1103)를 통해 상호 연결될 수 있다. 입력 신호(1104)를 뉴런($N_0, \dots, N_7$)에 연결하는 시냅스 요소(2)의 양의 가중치, 또는 한 쌍의 뉴런($N_0, \dots, N_7$)을 상호 연결하면, 시냅스-후 뉴런($N_0, \dots, N_7$)이 여기된다. 이들 연결 시냅스 요소(2)의 음의 가중치는 시냅스-후 뉴런($N_0, \dots, N_7$)의 억제를 초래하고, 이들 연결 시냅스 요소(2)의 가중치가 0이면 시냅스-후 뉴런($N_0, \dots, N_7$)에 연결되지 않는다.
- [0148] 뉴런($N_0, \dots, N_7$) 및 시냅스 요소(2), 상호 연결 토폴로지에 대한 구성 매개 변수 및 출력 스테이지 구성 매개 변수는 스파이킹 뉴런 네트워크(1100)가 초기화 상태로 설정될 때마다 구성 메모리로부터 로드될 수 있다. 이 작업은, 로드된 상호 연결 토폴로지 및 시냅스 가중치에 따라 뉴런($N_0, \dots, N_7$)이 상호 연결되도록 하고, 관련 로드된 구성 매개 변수에 따라 뉴런 및 시냅스 요소 매개 변수가 초기화되도록 하고, 관련 로드된 구성 매개 변수에 따라 시스템 매개 변수가 초기화되도록 하고, 출력 사전 또는 해시 테이블이 구성 메모리에 저장된 항목으로 채워지도록 한다.
- [0149] 입력 신호(1104)는 시냅스 요소(2)의 서브-세트에 제출되고, 네트워크(1100)는 출력 디코더로 전송될 수 있는 특정 출력(1105)을 생성한다.
- [0150] 스파이킹 뉴런 네트워크(1100)는 도 11에 도시된 바와 같이 구현될 수 있으며, 도 11은 설명된 뉴런 네트워크 스테이지들의 뉴런($N_0, \dots, N_7$) 및 시냅스 요소(2)에의 예시적인 매핑을 도시하는 구성된 시냅스 어레이(1202)의 예를 보여준다.
- [0151] 입력 인코더 스테이지(1211A, 1211B), 데이터 융합 스테이지(1212) 및 분류기 스테이지(1213)는 스파이킹 뉴런 네트워크(1200)에 예시된 바와 같이 구현될 수 있다. 출력 변환은 디지털 논리 회로를 사용하여 구현될 수 있고, 해시 테이블/사전 조회 작업은, 일 실시 예에서 스파이킹 뉴런 네트워크를 수반하는 마이크로프로세서에서 실행되는 소프트웨어 코드로서, 다른 실시 예에서는 디지털 논리 회로를 사용하여, 구현될 수 있다.
- [0152] 네트워크 스테이지(1211A, 1211B, 1212, 1213) 각각의 기본 원리는 동일하며, 각 스테이지(1211A, 1211B, 1212, 1213)는, 입력 자극이 제공될 때, 그 구성 매개변수에 따라 고유한 응답을 생성한다. 입력 인코더 스테이지(1211A, 1211B)의 목적은 입력 패턴 신호(1204A, 1204B)에 존재하는 각각의 고유한 특징에 대해 고유한 응답


을 생성하는 것일 수 있다. 데이터 융합 스테이지(1212)의 목적은 입력 인코더 스테이지(1211A, 1211B)로부터의 입력 스파이크 열의 각각의 고유한 조합에 대해 고유한 응답을 생성하는 것일 수 있다. 분류기 스테이지(1213)의 목적은 각각의 고유한 특징 또는 특징들의 조합에 대해 고유한 분류 응답을 생성하는 것일 수 있다.

[0153] 하나 이상의 실시 예는 컴퓨터 시스템과 함께 사용하기 위한 컴퓨터 프로그램 제품으로 구현될 수 있다. 프로그램 제품의 프로그램(들)은 실시 예의 기능(여기에 설명된 방법들을 포함)을 정의할 수 있으며 다양한 컴퓨터 판독 가능 저장 매체에 포함될 수 있다. 컴퓨터 판독 가능 저장 매체는 비일시적 저장 매체일 수 있다. 예시적인 컴퓨터 판독 가능 저장 매체는 다음을 포함하지만 이에 제한되지는 않는다: (i) 정보가 영구적으로 저장될 수 있는 쓰기 불가능한 저장 매체(예를 들어, CD-ROM 드라이브에 의해 판독 가능한 CD-ROM 디스크, ROM 칩 또는 임의의 유형의 솔리드-스테이트 비휘발성 반도체 메모리와 같은 컴퓨터 내 읽기 전용 메모리 장치); 및 (ii) 변경 가능한 정보가 저장될 수 있는 쓰기 가능한 저장 매체, 예를 들어 하드 디스크 드라이브 또는 임의의 유형의 솔리드-스테이트 랜덤 액세스 반도체 메모리, 플래시 메모리.


[0154] 상기 실시 예 중 둘 이상은 임의의 적절한 방식으로 조합될 수도 있다.

도면


도면1




도면2




도면3a




도면3b




도면4




도면5a




도면5b




도면6




도면7a




도면7b




도면8



도면9



도면10



도면11

