

오류-역전파 네트워크를 통한 인간의 미래 위치 예측

김승연^o 구훈정⁺ 송하윤

홍익대학교 컴퓨터공학과, 고려대학교 심리학과⁺

brdosa@naver.com, hoonjungkoo@gmail.com, hayoon@wow.hongik.ac.kr,

Future Location Prediction of Human Through Back-propagation Network

SungYun Kim^o Hoon Jung Koo⁺ Ha Yoon Song

Department of Computer Engineering, Hongik University Department of Psychology, Korea University⁺

요 약

인간은 일주일 단위로 유사한 행동 패턴을 가진다고 한다. 이런 점에서 일주일 단위의 시간-공간 기록의 형태인 인간 이동 데이터를 이용하면, 인간의 행동 패턴을 유추해 낼 수 있다. 본 논문에서 인간의 행동을 유추하기 위해 BPN알고리즘을 사용하였다. BPN알고리즘에 대해 설명하고, 인간 이동의 예측에 관한 적용에 관한 BPN알고리즘의 설계 과정을 논의한다. 그리고 해당 실험의 결과와 분석을 제시한다.

이다.

1. 서 론

인간 이동패턴은 과거부터 현재까지 많은 인간들의 관심이 있었고 또한 연구가 있어왔다. 하지만 완벽하게 인간의 이동 패턴을 예측한 연구는 없었다. 그 이유는 인간의 행동은 한 가지 변수로만 판단하기에는 상당히 복잡한 존재이기 때문이다. 그리고 여러 복합적인 변수를 감안 하더라도 그 변수가 너무 많기 때문에 예측을 하기에는 여러 난관이 있다고 생각한다.

인간의 행동을 예측하는데 필요한 자료는 많다. 시간, 개인의 성격(BFI-K), 재산 상황 등 여러 가지가 있다. 본 논문에서는 주로 시간의 변수를 감안하여 행동 예측 알고리즘을 설계할 예정이다.

시간과 인간행동에 관련된 연구에서 인간은 일주일 단위의 행동은 시간에 영향을 많이 받는다고 한다. 따라서 시간 변수에 대한 높은 예측이 가능한 알고리즘이 필요하다. 많은 방식 중 BPN(Back Propagation Network) 알고리즘의 이용을 시도하였다. BPN을 이용하여 인간의 이동 패턴을 예측하기 위한 시도를 보이는 것이 본 논문의 목표이다.

색션 2에서는 앞서서도 언급했던 BPN알고리즘에 대한 간단한 설명을 할 것이다. 색션 3에서는 설명한 BPN알고리즘에 기반하여 어떻게 행동 예측 알고리즘을 구성하였으며, 관련 변수를 어떻게 정하였는지 설명하고, 그 결과를 보여줄 것이다. 그리고 마지막 색션에서는 해당 연구의 개선 방향과 연구의 방향에 대해서 언급하게 될 것

2. BPN(back-propagation Network) 알고리즘

BPN 알고리즘(back-propagation algorithm)에 대해 언급하기 전에 우선 뉴로 컴퓨터(신경망)의 역사를 간략하게 이해할 필요가 있다. 뉴로 컴퓨터(신경망) 1943년 W.McCulloch와 W.Hartley에 의해서 처음 제시되었다. 해당 뉴런에 입력되는 자극의 합이 임계치보다 크면 뉴런이 활성화 되지만 임계치 보다 작으면 활성화 되지 않는 개념으로 동물의 역치 이상의 자극에만 반응하는 신경에 영향을 받아 설계하였다. 그리고 이 개념에 영향을 받아 1982년 D.Parker에 의해 BPN알고리즘이 개발되게 되었다.[5]

BPN알고리즘은 출력층의 오차 신호를 이용하여 은닉층과 출력층간의 연결강도를 변경하고, 또한 출력층의 오차 신호를 은닉층에 연전파하여 입력층과 은닉층과의 연결강도를 변경하는 학습법이다. 우선 크게 학습 단계를 3개로 나누어 보면. 1)학습패턴을 입력하여 출력을 구한다. 2)출력과 목표치의 오차를 구한다. 3)오차 값을 역전파로 전파시키면서 출력층의 연결 강도 및 은닉층의 연결 강도를 변경한다.

BPN알고리즘을 사용하기 위해 우선 연결강도 V 와 W 를 임의의 작은 값으로 초기화하고, 학습시킬 P 개의 학습 패턴을 설정한다.

그 후 적절한 오차 한계치 E_{max} 를 결정하고 학습 패턴을 순서대로 입력한다.

은닉층의 가중합 $N.E.T_z$ 와 출력 값 Z 를 다음과 같이

구한다.

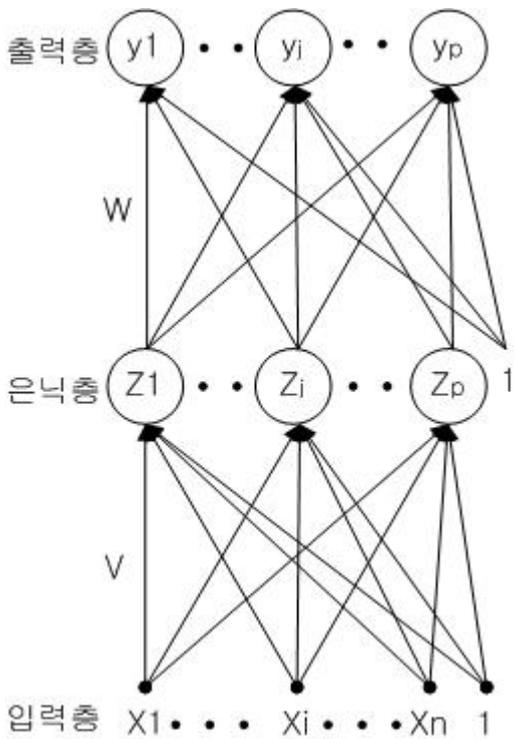
$$N.E.T_z = XV^T \quad (1)$$

$$Z = f(N.E.T_z) = \frac{1}{1/(1+e^{N.E.T_z})} \quad (2)$$

출력층의 입력 가중합 $N.E.T_z$ 와 최종 출력 y 를 구한다.

$$N.E.T_y = ZW^T \quad (3)$$

$$y = f(N.E.T_y) = \frac{1}{1/(1+e^{N.E.T_y})} \quad (4)$$



<그림 1> 시각화한 BPN

마찬가지로 입력층과 은닉층간의 연결 강도 변화량 목표치 d 와 최종출력 y 를 비교하여 오차 E 를 구한다.

$$E = \frac{1}{2}(d - y)^2 \quad (5)$$

출력층과 오차층의 오차신호 δ_y 와 δ_z 를 구한다.

$$\delta_y = (d - y)y(1 - y)$$

$$\delta_z = z(1 - z) \sum_{i=1}^m \delta_y w$$

은닉층과 출력층간의 연결강도 변화량 ΔW 를 계산하고 다음 학습에 사용될 연결강도 W_{k+1} 을 구한다.

$$\Delta W = \alpha \delta_y Z \quad (6)$$

$$W_{k+1} = W_k + \Delta W \quad (7)$$

ΔV 를 계산하여 다음 학습에 사용될 연결강도 V_{k+1} 를 구한다.

$$\Delta V = \alpha \delta_z X \quad (8)$$

$$V_{k+1} = V_k + \Delta V \quad (9)$$

위의 계산이 끝난 후 식 (5)에서 구한 오차 값을 E_{max} 의 값과 비교하여 만약에 더 클 경우 식 (1)부터 다시 시작하고, 작을 경우 학습을 종료하게 된다.

3. 실험

본 논문에서는 BPN알고리즘을 입력 노드 8개, 출력 노드 4개로 설정하여 사용하였다. 앞의 노드 8개는 시간 데이터의 입력을 의미하며, 뒤의 4개의 노드는 위치정보를 출력하는데 사용될 것이다.

실험을 진행하기 위해 입력 노드에 사용할 이동 데이터 값을 BPN알고리즘에 맞게 변경할 필요가 있다. 시간 데이터의 경우 1번째 노드는 AM/PM을 구분하는 노드로 사용하였고 0은 오전 1은 오후를 나타내도록 하였다. 뒤의 2 ~ 5번 노드는 시간을 이진법의 데이터로 바꾸어 사용하였다. 그리고 마지막 6 ~ 8번 노드는 요일을 나타내도록 하였다. 이것한 시간적 요인에 관한 가정은 인간의 이동 패턴은 1주일 단위로 반복한다는 것에 기인한다.[1]) <그림 2>에 나타난바와 같이 예를 들어 수요일 오후 7시는 10111010으로 나타낼 수 있다.

입력 데이터								출력 데이터			
0	0	0	0	0	0	0	0	-1	-1	1	0
0	0	0	0	1	0	0	0	-1	-1	1	0
0	0	0	1	0	0	0	0	-1	-1	1	0
0	0	0	1	1	0	0	0	-1	-1	1	0
0	0	1	0	0	0	0	0	-1	-1	1	0
0	0	1	0	1	0	0	0	-1	-1	1	0
0	0	1	1	0	0	0	0	-1	-1	1	0
0	0	1	1	1	0	0	0	-1	-1	1	0
0	1	0	0	0	0	0	0	-1	-1	1	0.5
0	1	0	0	1	0	0	0	-1	-1	0.3	1
0	1	0	1	1	0	0	0	-1	-1	0	1
1	0	0	0	0	0	0	0	-1	-1	0	1
1	0	0	0	1	0	0	0	-1	-1	0	1
1	0	0	1	0	0	0	0	-1	-1	0	1
1	0	0	1	1	0	0	0	-1	-1	0	1
1	0	1	0	0	0	0	0	-1	-1	0	1
1	0	1	0	1	0	0	0	-1	-1	0.3	1
1	0	1	1	0	0	0	0	-1	-1	0.5	1
1	0	1	1	1	0	0	0	-0.3	-1	0.5	0.5
1	1	0	0	0	0	0	0	0.3	-1	1	0.3
1	1	0	0	1	0	0	0	1	-1	0	0
1	1	0	1	0	0	0	0	1	-1	0.5	0

<그림 2> BPN알고리즘 입력 데이터 예시

출력 데이터의 학습시키는 과정에 각각의 위치 정보에 가중치를 두어 사용하였다. 예를 들면 특정 어느 시간에 A대학에 있을 확률이 높으면 1값을 주고 그 외의 장소에는 -1값을 주어 가능성이 거의 없음을 표시하였다.

4. 결과 및 분석

위 실험을 시행할 때 우선 입력 데이터를 기초로 한 학습 과정을 거쳐야 한다. 학습한 후의 각각 노드의 가중치는 <그림 3>와 같다.

입력층과 은닉층간의 연결강도										
	1	2	3	4	5	6	7	8	9	10
1	-2.07	-4.85	2.19	-0.17	0.62	-4.08	1.94	-1.65	-6.01	0.39
2	12.06	-2.33	-10.21	4.22	1.34	-3.91	-5.77	-9.68	-10.9	-0.52
3	-13.16	-2.27	-6.34	-6.45	4.04	0.44	-2.66	3.82	-0.36	6.14
4	-4.06	0.08	-4.12	-0.15	0.79	2.23	6.68	-2.83	-0.47	-5.64
5	-4.12	0.68	-3.95	0.85	-0.22	6.26	-0.73	-3.10	3.85	-11.2
6	2.57	1.64	2.34	-0.11	0.13	6.19	1.91	4.70	0.19	-7.20
7	-6.27	2.71	3.47	-4.31	-6.17	-4.73	-7.18	0.41	10.7	-5.83
8	0.98	1.28	-2.49	-0.22	-0.46	0.09	1.21	0.75	9.17	-0.61

은닉층과 출력층간의 연결강도				
	1	2	3	4
1	-2.8057	-3.414	-20.2	3.52334
2	9.44575	8.44284	-1.2864	6.66678
3	-2.6822	-1.593	21.8312	-7.9888
4	-20.515	-17.211	-0.5573	16.487
5	14.7663	-24.123	-0.4617	-6.503
6	-16.17	-13.985	1.99474	-10.301
7	-15.663	-9.3485	19.1275	-3.7909
8	-18.718	-17.713	-25.656	-7.5152
9	-19.33	-17.922	7.40189	-20.312
10	-13.735	4.61196	20.6157	4.08468

<그림 3> BPN알고리즘의 가중값

<그림 3>은 입력층-은닉층, 은닉층-출력층 사이의 가중치 값을 나타낸다. 이 각각의 값이 <그림 1>의 V와 W에 들어갈 값들이다. 예를 들어 왼쪽에서 가장 위쪽의 값은 첫 번째 입력 노드와 첫 번째 은닉노드사이의 가중치 값이다.

이렇게 구한 가중치 값을 이용하여 입력 노드에 원하는 시간을 넣으면 해당 데이터의 현재위치를 가능성에 입각하여 데이터로 표현해준다. <그림 4>은 데이터를 통합하여 나타낸 것이다.

<그림 4>에서 왼쪽에 있는 값이 입력 값이고, 오른쪽에 있는 값이 입력 값을 판별한 출력 값이다. 출력 값의 경우 1에 가까울수록 해당 위치에 있을 확률이 높은 것이고, 반대로 적을 경우 해당 위치에 있을 확률이 적은 것이다. 예를 들어, 오전 2시~6시의 경우 출력 값 'B'이 1로 찍힌 것을 볼 수 있다. 이런 경우 'B에 있을 확률이 아주 높다' 라고 말할 수 있다.

다른 경우로, 출력 값 두 개가 서로 비슷한 경우가 있다. 이때는 두 점간에 존재할 확률이 비슷하다는 것으로, 두 점 위에 있거나 아니면 두 점 사이를 이동한다고 볼 수 있다. 예를 들어, 오후 7시의 경우 'B'와 'C'에 있을 확률이 각각 0.441309, 0.46081로 비슷함을 알 수 있다. 이런 경우 'B 또는 C에 있을 확률이 있다, 아니면 B 또는 C 사이를 이동하고 있을 수도 있다' 라고 말할 수 있다.

입력 값	결과 값			
	위 치			
시 간	A	B	C	D
0	1.25E-22	2.81E-29	0.989038	1.04E-10
1	1.21E-08	1.92E-21	0.98	5.68E-08
2	4.42E-10	5.97E-27	0.99	2.60E-06
3	2.77E-07	2.62E-17	0.99	1.55E-05
4	1.05E-17	6.44E-27	0.98	5.01E-05
5	1.31E-15	5.72E-24	0.98	0.002
6	1.34E-15	2.25E-24	0.97	0.01001
7	4.45E-10	1.58E-17	0.978166	0.4248
8	1.98E-16	5.50E-27	0.63273	1
9	3.36E-05	3.03E-20	0.193875	0.999994
10	2.95E-14	7.35E-28	1.53E-05	0.999997
11	5.17E-08	6.85E-18	1.51E-05	9.80E-01
12	7.66E-07	2.95E-20	1.05E-08	9.80E-01
13	1.89E-06	1.73E-19	1.14E-09	9.70E-01
14	1.42E-12	5.89E-25	1.64E-08	0.979093
15	4.14E-11	3.13E-23	0.048651	0.999953
16	1.44E-15	3.82E-27	0.267599	0.970341
17	4.21E-15	1.60E-26	0.498954	0.972034
18	2.05E-18	2.02E-29	0.46081	0.441309
19	0.304432	7.16E-10	1	0.28514
20	0.988789	1.64E-13	0.024847	0.003566
21	0.999479	8.81E-14	0.496101	0.002999
22	0.00886	1.94E-18	0.782126	7.51E-07
23	3.70E-09	7.30E-22	0.98	4.30E-09

<그림 4> BPN알고리즘으로 학습한 결과.

5. 향후 연구 방향

본 논문의 연구방식에 개선할 부분이 존재한다. 대표적으로 실험한 데이터의 값이 개인의 데이터에 한정되어 있다는 점이나, 반복되는 일상에서만 적용되는 점이 있다.

또한 앞에서 언급했던 심리적인 부분이나, 개인의 특성을 고려하지 않았고 또한 시간의 단위 또한 최소 시간의 단위가 '시(hour)' 임을 들어, 아직은 출력되는 결과가 정확한 이동 패턴을 예측하기에는 신빙성이 없다고 생각되어진다.

이런 문제점을 해결 및 개선하기 위한 몇 가지 연구 전망이 있다. 우선, 다양한 데이터 표본의 필요성이다. 본 논문의 경우 한명분의 데이터만을 사용했기 때문에 만족스러운 결과가 나왔을 수도 있을 가능성이 있다. 따라서 좀 더 많은 표본 데이터를 사용하여 해당 알고리즘의 정확도를 올릴 필요가 있겠다. 이렇게 좀 더 정확해진 알고리즘을 가지고 후에 Big Data와의 접목이 가능하리라 생각된다.[5]

두 번째로, 심리학적인 요소를 추가하여 알고리즘을 개선하는 것이다. 선행 연구[4]에서 인간의 이동을 모델링 하는 과정에서 고려되어야 하는 심리학적 요소로 인구통계학적 요소, 인지적 판단 요소, 정서적 요소 및 기타 요소의 4가지 카테고리가 제안된 바 있다. 추후 연구에서는 이 중 정서적 요소로서 성격요인을 파악하고 이를 분석하여 인간의 이동경로 예측 및 모델링의 정확도를 높이는 기초적 파라미터를 확보할 것이다. 이를 위해 현재 자기보고식 성격유형평가인 Big Five Inventory[3]를 이용하여 인간의 5가지 성격 요인을 측정하고 이를 이동패턴을 예측하는 Parameter의 하나로 활용하는 연구를 진행 중이다. 예를 들어, 5가지 성격 요인 중 하나인 외향성과 우호성향을 많이 보이는 사람의 경우 출퇴근을 반복하는 규칙적 패턴에서 벗어나는 불규칙적 패턴을 보일 확률이 높을 것이며, 카페나 주점 등이 밀집해있는 지역으로의 이동 경로를 선택할 확률이 높을 것으로 가정할 수 있다. 반면, 내향성이며 성실성향이 높은 사람의 경우 변화에 대한 저항이 높을 수 있으므로 일정 이동 경로를 반복하는 규칙적 패턴을 보일 확률이 높을 것이라고 가정할 수 있을 것이다[6]. 이는 같은 알고리즘 내의 분산 즉, 개인차 요소를 설명해줄 수 있을 것으로 기대된다.

마지막으로, 마코프 연쇄(Markov Chain)으로 표현된 인간의 이동 모델과의 연관성을 고려할 수 있다. 마코프 연쇄는 상태(state)를 장소로, 전이확률(transition probability)을 상태간의 이동 확률로 표현해 준다[7]. 한 개인의 이동 모델이 마코프 표현되어 공간적 전이 확률을 나타낼 때, 이를 적용하여 BPN 알고리즘의 기저로 이용할 경우, 각 개인의 규칙적 행동에 대한 학습이 강건(robust)해지며, 규칙적이지 못한 행동에 대한 좀 더 높은 확률적 예측이 가능해질 것이다.

6. 사 사

이 논문은 2012년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2012046473 및 No. 20120007162).

7. 참고문헌

[1] Chaoming Song, Zehui, Qu, Nicholas Blumm, Albert-Laszlo Barabasi, "Limits of predictability in human mobility", *Science*, Vol.327, pp.1018-1021, 2010

[2] Jillian Anable, "'Complacent Car Addicts' or 'Aspiring Environmentalists'? Identifying travel behaviour segments using attitude theory", *Transport Policy*, Vol.12, pp.65-78, 2005

[3] Walter Mischel, 손정락 역, 성격심리학, 시그마프레스

출판사, ch-3, pp.273-293, 2006

[4] 이 석 중, 인간 이동 모델에 영향을 주는 심리학적 변인의 분석, 한국 정보처리학회 제37회 추계학술발표대회 논문집, 2011

[5] 오 창 석 저, 뉴로 컴퓨터 개론, 내하 출판사, ch-13, pp.273-293, 2000

[6] Bas Verplanken, Henk Aarts, Ad Van Knippenberg, "Habit, information acquisition, and the process of making travel mode choices", *European Journal of Social Psychology*, 27, pp.539-560, 1997.

[7] Hyunuk Kim and Ha Yoon Song, "Formulating Human Mobility Model in a Form of Continuous Time Markov Chain," The 3rd International Conference on Ambient Systems, Networks and Technologies, August 27-29, 2012, Niagara Falls, Ontario, Canada.