

속성적 관점에 기반한 단어 재인시의 의미 처리 가능성 연구: 연결주의 모델링*

유 희 조 남 기 춘 남 호 성[†]
고려대학교 심리학과 고려대학교 영문학과

단어의 의미처리는 개별 단어가 나타내는 개념(concept)들 간의 의미적 관련성을 효과적으로 표상할 수 있어야 한다. 본 연구는 의미 처리의 모델로서, 속성적 관점에 기반한 연결주의 모델을 제시하고, 단어와 의미 간의 관계를 학습하였다. 학습 과정 이후 모델용의 어휘 판단 과제를 수행하여, 종래 행동실험에서 의미 처리와 관련되어 나타나는 것으로 언급되었던 효과들이 제대로 모사되었는가 통계적으로 검증하였다. 모델링 수행 결과, 모델은 빈도효과(frequency effect), 단어 유사성 효과(word similarity effect), 의미 충실도 효과(semantic richness effect)와 의미 접화 효과(semantic priming effect)를 정상적으로 모사하는데 성공함으로써, 모델이 정상적인 의미의 학습 및 처리가 가능함을 보였다. 본 연구의 결과는, 속성적 관점 기반의 의미 표상(representation) 구조가 충분히 실제 사람의 언어처리를 반영할 가능성을 제시한다.

주제어 : 개념 표상, 의미 처리, 속성적 관점, 연결주의 모델링

* 이 논문 또는 저서는 2013년 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (NRF-2013S1A5A2A01019273).

이 연구는 2015년도 고려대학교 학제간 연구회 지원을 받아 수행되었음(과제번호: K1505131)

[†] 교신저자 : 남호성, 고려대학교 문과대학 영문학과, (02841) 서울특별시 성북구 안암로 145 안암동 5가 고려대학교 인문사회캠퍼스 라이시움 313호, E-mail : hnam@korea.ac.kr

의미(semantic) 정보의 처리 메커니즘은 인간의 인지과정 전반에 있어 중요하게 다뤄져 왔다. 특히, 언어심리학 영역에서 의미는 철자나 소리에 관한 연구만큼 중요한 하나의 연구 2002; Johnson-Laird, Herrmann, & Chaffin, 1984; Vigliocco & Vinson, 2007).

의미 정보 처리 메커니즘을 알아보기 위해 시행되는 행동실험 중 하나로 어휘 판단 과제 (lexical decision task)를 들 수 있다. 어휘 판단 과제는 단어 자극을 시각적, 청각적으로 제시 하고, 제시된 자극이 실제 단어인지, 아니면 무의미한 시각적 철자 혹은 청각적 음절의 나열인지를 판단하는 과제이다. 어휘 판단 과제는 빈도, 길이, 의미적 관련성 등이 이 판단에 영향을 끼치는 것으로 알려져 있다 (김지혜, 2010; 남기춘 외, 1997; 박권생, 1997; 송진영, 남기춘 & 구민모, 2012; 임형욱 2004; Yim, Lim, Park, & Nam, 2005).

전통적으로 의미 표상에 관해 제안된 구조 들은, 개념(concept)을 독립적인 하나의 단위로 상정하였다. 이런 전체론적 관점(holistic view)은 각각 독립된 개념이 어떤 식으로 관계되어 있고, 어떻게 구성되어 있는지, 어떻게 영향을 주고받는지에 초점을 맞추고, 이를 바탕으로 의미 표상 구조에 관해서 논의하였다. 그리고 이런 전체론적 관점에서 제안된 구조들은 크게 두 종류가 있다.

이런 전체론적 관점에서 제시된 모델중 하나로, 위계적 연결망 모형(hierarchical network model)이 있다. 위계적 연결망 모형은 각 개념이 위계적으로 서로 연결되어 있음을 전제하고, 상위 개념이 하위 개념을 포함하는 형태로 표현한다. 예를 들어, ‘야채’는 ‘당근’, ‘오

이’와 같은 다양한 하위 개념을 보유하고 있으며, 동시에 ‘식물’과 같은 상위 개념에 포함되는 하위 개념이기도 하다. 위계적 연결망 모형에서는, 이렇게 형성된 위계적 연결이 연관된 개념을 표상하는데 활용된다고 제안되었다 (이광오 & 박현수, 2009; Collins & Quillian, 1972; Harm, 2002; Johnson-Laird et al., 1984; Reed, 2000; Vigliocco & Vinson, 2007). 하지만, 이와 같은 종속성에 기초한 위계적 연결망 모형에는 전형성 효과(typicality effect)와 같은 동일 위계 내에서 발생하는 반응의 차이를 설명하기 어려웠다. 전형성 효과란, 어떤 범주 내에서 해당 범주에 소속되는 가장 일반적인 자극에 대한 반응이, 다른 자극에 대한 반응보다 빠르게 나타나는 현상을 의미한다. 예를 들어, ‘새’라는 개념의 하위 개념에는 ‘참새’, ‘펭귄’ 등이 포함되어 있으며, 참여자들이 이에 대해 제시된 자극이 선행 제시된 범주에 속하는지 판단하게 하는 범주 확인 과제 (category verification tasks)를 수행한다. 과거 연구들은 범주 확인 과제의 수행에서, ‘펭귄’보다 더 ‘새’로 에 가까운 ‘참새’가 훨씬 빠르고 정확하게 구별해냄을 보여 왔다(Fujihara, Nageishi, Koyama, & Nakajima, 1998; Lei, Li, Long, Li., Chen, Ni, & Li, 2010; Rips, Shoben, & Smith, 1973). 하지만 위계적 연결망 모형에서는, 같은 층위에 속해 있는 개념들은 동일한 형태의 처리 과정을 전제하므로, 이와 같은 전형성 효과를 표현하기 어렵다.

전체론적 관점에 의한 또 하나의 모델로는 활성화 확산 모형(spreading-activation model)을 들 수 있다. 활성화 확산 모형은 전체론적 관점의 모델로서 각 개념들이 독립적으로 표상

된다는 점에서는 위계적 연결망 모형과 유사하다. 하지만 위계적인 관계보다는 개념들 상호간의 의미적 연관성에 초점을 맞춘 모형이다. 활성화 확산 모형에서는 서로 관련성이 있는 개념들을 연결하는 연결들이 존재하며, 이 연결의 거리 혹은 두께가 연결된 개념들 간의 연결 강도를 나타낸다. 그리고 이 연결들은 어떤 하나의 개념이 활성화되었을 때, 그 활성화를 전달하는 역할을 하게 된다. 따라서, 개념 간의 거리가 가까울 경우 그 활성화의 전달 강도는 강해지며, 반대로 개념 간의 거리가 증가할 경우 그 전달 강도 역시 약해지게 된다(이광오 & 박현수, 2009; Bock & Levelt, 2002; Collins & Loftus, 1975; Dell, 1986; Reed, 2000; Vigliocco & Vinson, 2007).

한편, 이런 전체론적 관점에 대비되는 형태로, 속성적 관점(featural view)이 제시되었다. 전체론적 관점과 비교할 때 속성적 관점이 갖는 가장 큰 차이점은 기본적인 개념 표상의 단위가 속성이라는 점이다. 속성적 관점에서, 속성은 개념에 종속적이지 않고 독립적으로 존재하며, 반대로 개념은 독립적인 표상이 존재하지 않는다. 대신에 다수의 속성들로 구성된 패턴 자체가 개념으로서 기능하게 된다. 가령, ‘포유류’라는 개념이 표상될 때, ‘젓을 먹임’, ‘육지에 있음’, ‘생물’과 같은 속성들이 동시다발적으로 활성화됨으로써, 이런 속성들의 조합 자체가 ‘포유류’라고 하는 개념이 되는 식이다(Hinton & Shallice, 1991; McRae, Cree, Seidenberg, & McNorgan, 2005; Plaut, 1997; Vigliocco & Vinson, 2007).

비단 표상 구조만이 아니라, 전체론적 관점과 속성적 관점 간에는 ‘서로 다른 개념 간의

관계 표현 방식’이라는 차이 또한 존재한다. 위에서 언급한 것처럼 전체론적 관점, 특히 개념 간의 연결을 중시하는 위계적 연결망 모형과 활성화 확산 모형에서 개념들은 서로 연결되어 있으며, 이 연결을 통해 의미적 관련성에 의한 효과들을 설명한다.(이광오 & 박현수, 2009; Bock & Levelt, 2002; Vigliocco & Vinson, 2007).

한편 속성적 관점은 전체론적 관점에서 제시하는 연결에 의한 설명이 불가능하다. 개념은 속성들의 조합, 즉 전체 속성의 활성화 패턴으로 표현되므로, 따로 개별적 연결이 존재하지 않기 때문이다. 대신 속성적 관점에서는 속성들 간의 겹침(overlap)에 의해 개념 간의 관계를 표현한다. 즉, 두 개념이 많은 속성이 겹칠 경우, 의미적으로 유사한 개념이 된다. 문제는 속성들 간의 겹침이, 반의어 혹은 종속성과 같은, 유사성을 제외한 다른 형태의 의미적 관련성을 효과적으로 설명할 수 있는가 이다(McRae et al., 2005; Vigliocco & Vinson, 2007).

가령, 어휘 판단 과제에서 나타나는 의미 점화 효과(semantic priming effect)는, 위에서 언급한 다양한 의미적 관련성이 고려되어야 할 현상 중 하나이다. 의미 점화 효과는 선행적으로 제시되는 점화 자극이 목표 자극과 의미적으로 연관되어 있을 때가, 관련되지 않았을 경우보다 반응시간 및 오류율이 감소하는 현상을 의미한다(김선경, & 이혜원, 2007; 김지혜, 2010; 이창환, 김연희, & 강봉경, 2003; Cree, McRae, & McNorgan, 1999; Park & Lim, 2014). 개념 간 연결에 의해 의미 점화 효과를 설명하는 전체론적 관점에 비해서, 직접적 연

결을 전제하지 않고 겹침에 의한 유사성으로 의미적 연관성을 제시하는 속성적 관점은 설명이 제한적일 수밖에 없다. 따라서, 속성적 관점의 입장에선, 종속적 혹은 반의적인 관계 등을 점화할 수 있는가에 대한 검증이 필요하다.

모델링 연구는 이런 검증에 대한 한 가지 수단이 될 수 있다. 연결주의 모델링(connectionist modeling)의 장점으로는 크게 두 가지를 들 수 있다. 첫째로 연결주의 모델링 연구에서는 연구자가 가정하는 대로 내적인 구조를 구축 가능하며, 과제에 대한 시뮬레이션을 통해 이 구조의 타당성이 검증 가능하다(Plaut, 1996, 1997; Seidenberg & McClelland, 1989; Yermolayeva & Rakison, 2014). 이는 속성적 관점의 검증을 위해서 개념을 표상하는 구조를 의도적으로 속성 단위의 표상 구축이 가능함을 의미한다. 둘째로 연결주의 모델링 연구는 학습에 의한 모델의 점차적인 수행 변화를 전제하며, 이에 따라 연구의 필요성에 의해 학습에 사용될 자극 및 학습 시기도 통제가 가능하다(Jacobs & Jordan, 1991; Plaut, 1996, 1997; Yermolayeva & Rakison, 2014). 비록 속성적 관점의 검증에 있어서 학습 자극과 학습 시기의 통제가 주요 변인이 아니라 할지라도, 이 장점은 학습 단계에서 무작위성을 확보함으로써, 개인차에 대한 개념을 일부 반영 가능하도록 한다.

더불어 의미처리에 관한 과거 국내외의 연결주의 모델링 연구들이 속성적 관점을 적용해 왔다는 점 또한, 속성적 관점의 검증에 연결주의 모델이 사용될 수 있는 중요한 이점이다. 속성적 관점이 적용된 연결주의 모델링의

하나로 Plaut(1997)의 모델을 들 수 있다. Plaut(1997)는 연결주의 모델이 어휘 판단 과제를 어떤 식으로 처리 가능한지를 제안하고자 하였으며, 철자층(grapheme layer)과 음운층(phoneme layer), 의미층(semantic layer)로 구성된 의미 정보의 처리가 가능한 모델을 제시하였다. 그리고 임의로 200개의 속성을 가정하고 각 단어에 무작위로 속성을 부여하여 학습을 진행하였다. Plaut(1997)의 모델은 단어의 빈도와 단어/비단어의 차이에 따라 다른 패턴의 의미층의 활성화를 보임으로써, 연결주의 모델의 어휘 판단 과제 수행이 가능함을 보였다(Plaut, 1997).

또 다른 속성적 관점의 연결주의 모델은 Cree et al.(2006)의 모델을 들 수 있다. Cree et al.(2006)은 의미 처리에서, 특정 속성이 다른 속성보다 표상에 핵심적인 역할을 할 가능성을 주장하였다. 그리고 Cree et al.(2006)은 이를 확인하기 위해, 철자층(orthographic layer)과 의미 속성층(semantic feature layer)으로 구성된 모델을 제시하였다. Plaut(1997)와는 다르게 Cree et al.(2006)은 McRae et al.(2005)에서 조사된 2,526개의 실제 속성들을 기반으로 자극을 구성하여 학습을 진행하였다. Cree et al.(2006)은 학습 중 모델 내에서의 가중치의 변화 양상을 분석함으로써 일부 속성이 의미 표상에 더욱 핵심적인 역할을 함을 보였다(Cree, McNorgan, & McRae, 2006; McRae et al., 2005; Plaut, 1997).

국내에서도 속성적 관점에 기반한 연결주의 모델의 연구가 진행되었다. 임형욱(2004)과 Yim et al.(2005)는 한국어 어휘 판단 과제에 대한 연결주의 모델을 통해 어휘 정보 처리의

특성을 밝히고자 하였다. 임형욱(2004)과 Yim et al.(2005)가 제안한 모델은 Plaut(1997) 모델에서 음운층을 제외한, 철자층과 의미층으로 모델을 구성하였으며, 철자층을 한국어의 자소 구조에 맞게 변경하고, 임의로 120개의 속성을 가정하여 각 단어에 무작위로 부여하였다. 모델은 빈도 효과(frequency effect), 어휘성 효과(word superiority effect) 및 단어 유사성 효과(word similarity effect)를 보임으로써, 어휘 정보 처리에서 철자 정보와 의미 정보가 자동적으로 영향을 끼칠 수 있음을 주장하였다 (임형욱, 2004; Yim et al., 2005).

Park et al.(2011)은 1음절 단어만 사용되었던 Yim et al.(2005)의 모델을 확장하여, 2음절 단어의 처리가 가능한 모델을 제시하였다 (Park, Jung, Lee, Lee, & Lim, 2011; Park & Lim, 2014). 그리고 Park & Lim(2014)은 Park et al.(2011)의 모델을 확장하여, 한국어 의미 정보 처리의 일반 현상을 설명할 수 있는 모델을 제안하고자 하였다. Park & Lim(2014)은 Park et al.(2011)의 모델에 맥락층(context layer)를 추가하였고, 제시한 모델이 Yim et al.(2005)가 보인 효과들에 더해 의미 점화 효과 또한 연결주의 모델로 구현이 가능함을 보였다(Park & Lim, 2014).

하지만 위와 같이 다수의 속성적 관점의 연결주의 모델이 제시되었음에도 불구하고, 여전히 속성적 관점이 온전하게 개념 간 연결성을 표현해 낼 수 있는가는 확실하지 않다. 이는 과거 모델들이 속성적 관점에 대한 검증을 위해 제시된 것이 아니기 때문이다.

Plaut(1997) 및 국내의 의미 처리를 위한 연결주의 모델들은 실제의 의미 정보가 아닌,

무작위로 할당된 의미 정보를 통해 그 효과를 구현하였고, 이에 따라 실제 언어에서 존재하는 철자 정보와 해당 단어가 보유한 개념과의 관계성을 제대로 반영하지 못하였다는 제한점이 있다(임형욱, 2004; Park et al., 2011; Park & Lim, 2014; Plaut, 1997; Yim et al., 2005).

또한 Cree et al.(2006)의 연구는 실제 속성들을 기반으로 자극을 구성하였지만, 학습에 사용된 자극의 양이 제한적이라는 점이 개념 간 관계성 구축에 제한이 될 수 있다. 본래 연결주의 모델의 학습에서는, 충분한 양의 학습 자극이 없을 경우, 정상적인 학습이 이루어질 수 없다. 그 결과, 철자와 개념이 패턴의 형태로 기억되어야 함에도 불구하고, 철자-속성의 일대일 매칭이 될 가능성이 발생한다. 이에 따라 같이 나타나서는 안 되거나, 빈번하게 같이 나타나는 형태와 같은, 속성들 간의 상호작용들이 학습되기 어려워진다. 따라서, 제한적인 자극의 양은 개념 간 관계성 구축 또한 정상적으로 이루어지기 어렵게 만든다 (Cree et al., 2006).

위와 같은 제한점으로 인해, 비록 연결주의 모델링이 속성적 관점의 검증에 대한 좋은 수단이 될 수 있음에도 불구하고, 과거 제시되었던 연결주의 모델링으로 속성적 관점에 대한 타당성 검증은 한계가 있다. 따라서, 위의 제한점들을 해소하는 다른 구조의 연결주의 모델링을 통해 검증이 필요할 것으로 판단된다.

본 연구는, 연결주의 모델링을 이용하여 속성적 관점이 철자-개념 및 개념들 간의 관련성을 효과적으로 표상 가능한지 알아보하고자 하였다. 또한 속성적 관점에서 과거 연구되었

던 의미 관련 효과들의 메커니즘을 검증해보고자 하였다.

이를 위해, 본 연구에서는 속성적 관점에 기반하여 의미 처리에 목적을 둔, 철자 정보를 통해 의미 정보를 산출하는 연결주의 모델을 구축하였다. 그리고 철자 정보에 대한 개념을 학습한 이후, 어휘 판단 과제의 시뮬레이션을 수행하였다. 그리고 이 시뮬레이션의 결과를 이용해 통해 종래 행동실험에서 의미 처리와 관련되어 나타나는 것으로 언급되었던 효과들이 제대로 반영되었는지를 통계적으로 검증하였다.

본 연구를 통해, 의미에 관련된 여러 효과에 대해 속성적 관점의 적용 가능성에 관하여 이해할 수 있을 것으로 기대하였다. 또한, 대규모 자극 목록과 실제의 의미 속성 사용을 통해 종래 모델링 연구들의 제한점인 소규모

자극목록, 개념 간의 관련성을 제대로 반영하지 못하는 임의의 속성 할당을 통해 생긴 실제 의미 구조와의 괴리를 해소할 수 있을 것으로 기대하였다. 그리고 추가적으로, 동일 구조의 모델을 독립적으로 여러 번 학습함으로써, 과거 모델링 연구들이 갖고 있던 모델 내에서의 통계분석으로 인해 발생하는 검증 단계에서의 문제점을 해소할 수 있을 것으로 기대했다.

방 법

모델링 구조 모델의 기본 구조는 그림 1과 같다. 이와 같은 구조는 과거 철자-의미 간의 관계에 초점을 맞추었던 모델링 연구들을 참고하여 구성되었다(Park et al., 2011; Plaut, 1997; Yim et al., 2005). 세부적으로는, 입력층

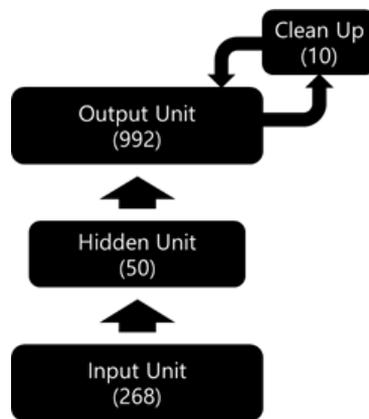


그림 1. 모델링의 구조. 아래로부터 각각 입력층(input layer), 은닉층(hidden layer), 출력층(output layer) 방향으로 각 층의 활성화(activation)가 전달되었다. 입력층은 268개의 단위(unit)로 구성되었으며, 철자 정보를 입력받았다. 은닉층은 50개의 단위로 구성되었다. 은닉층은 입력층의 활성화 값을 출력층으로 전달하였고, 이 전달과정에서 모델의 연산이 이루어졌다. 출력층은 992개의 단위로 구성되었으며, 은닉층으로부터 넘겨받은 활성화를 통해 최종적으로 의미 표상을 활성화시켰다. 정화층(clean-up layer)은 출력층의 값을 받아 다시 출력층으로 보냈다. 이 재귀적 과정은 모델의 성능 개선 및 작업 기억으로서 의미 집화를 시뮬레이션 하는데 이용되었다.

(input layer)은 철자정보(orthographic information)를 표상하며, 총 268개의 단위(unit)로 구성되었다. 입력층의 입력단위(input unit)는 각각 하나의 자소 정보를 표상하며, 이들의 조합을 통해 하나의 철자단어(orthographic word) 전체를 표상한다. 과거 한국어의 철자 표상에 관한 연결주의 모델링 연구에서는, 초성 19개, 중성 21개, 종성 27개로, 합계 67개의 단위로 하나의 음절을 표상하고, 이를 2배, 3배 함으로써 복수의 음절을 표상하는 구조를 사용하였다(임형욱, 2004; Park et al., 2011; Park & Lim, 2014; Yim et al., 2005). 본 연구 또한 이 구조를 일부 차용하였으나, 해당 구조에 더해 음절 위치에 관계없이 어느 음절에서 표상되더라도 활성화되는 67개의 단위를 추가로 구성하였다. 이는 ‘학교’와 ‘수학’과 같이, 음절 위치가 다름에도 실제 의미에 관련성이 있는 경우를 좀 더 명시적으로 표현하기 위함이었

다. 구체적인 구조는 그림 2와 같다. 그림 2의 1행에 해당하는 1-67번 단위는 음절 위치에 상관없이 해당 자소가 표상될 경우 1의 활성화 값을 갖게 되고, 각각 그림 2의 2, 3, 4행에 해당하는 68-134, 135-201, 202-268번 단위들은, 각각 1,2,3음절의 해당 자소가 표상될 경우 1의 활성화 값을 갖게 되며, 나머지 단위들은 모두 0을 갖는다(그림 2).

출력층(output layer)은 의미 정보(semantic information)를 표상하며, CoreNet을 참조하여 총 992개의 단위로 구성되었다. 입력단위와 유사하게 각 출력단위(output unit)는 하나의 의미 속성(semantic feature)을 표현하게 된다. 즉, ‘식품’이라는 개념에 대해서 표상할 경우 ‘물건’, ‘무생물’, ‘인공물’, ‘식료’, ‘식품’이라는 ‘식품’ 개념을 구성하는 속성에 해당하는 각 단위들이 모두 1이라는 목표값을 갖게 되고, 나머지 속성에 해당하는 단위들은 0을 목표값

	ㄱ	ㄴ	...	ㅅ	...	ㅌ	ㅋ	ㅍ	ㅎ	ㅈ	ㅊ	...	ㅊ	ㅊ	...	ㄱ	ㄴ	...	ㅅ	...	ㅌ	ㅋ	ㅍ	ㅎ
0	1	0	...	0	...	0	0	0	1	1	0	...	0	1	0	...	1	0	0	0	...	0	0	0
1	0	0	...	0	...	0	0	0	1	1	0	...	0	0	0	...	1	0	0	0	...	0	0	0
2	1	0	...	0	...	0	0	0	0	0	0	...	0	1	0	...	0	0	0	0	...	0	0	0
3	0	0	...	0	...	0	0	0	0	0	0	...	0	0	0	...	0	0	0	0	...	0	0	0

	ㄱ	ㄴ	...	ㅅ	...	ㅌ	ㅋ	ㅍ	ㅎ	ㅈ	ㅊ	...	ㅊ	ㅊ	...	ㄱ	ㄴ	...	ㅅ	...	ㅌ	ㅋ	ㅍ	ㅎ
0	1	0	...	1	...	0	0	0	1	1	0	...	0	1	0	...	0	0	0	0	...	0	0	0
1	1	0	...	0	...	0	0	0	0	0	0	...	0	1	0	...	0	0	0	0	...	0	0	0
2	0	0	...	1	...	0	0	0	0	1	0	...	0	0	0	...	0	0	0	0	...	0	0	0
3	0	0	...	0	...	0	0	0	0	0	0	...	0	0	0	...	0	0	0	0	...	0	0	0

그림 2. 입력층의 표상 예시. 상단은 ‘학교’라는 철자정보에 대한 표상이고, 하단은 ‘교사’라는 철자정보에 대한 표상이다. 1행(제목열의 0)은 음절 위치에 상관없이 해당 자소가 표상될 경우 1의 활성화 값을 갖게 되고, 각각 2, 3, 4행(제목열의 1, 2, 3)은 각각 1,2,3음절의 해당 자소가 표상될 경우 1의 활성화 값을 갖게 되며, 나머지 단위들은 모두 0을 갖는다.

으로 갖게 된다 (그림 3).

연결주의 모델링(connectionist modeling)에서 은닉층(hidden layer)은, 입력단위들의 활성화 값을 출력단위들로 전달해주는 역할을 맡으며, 각 모델의 연산능력은 은닉단위(hidden unit)의 개수와 정적 상관관계(positive correlation)를 갖는 것으로 알려져 있다 (Plaut, 1996; Seidenberg & McClelland, 1989; Seidenberg, 2005). 본 연구에서는 반복적인 파일럿 과정을 통해 가장 활성화 결과가 안정화되는 은닉층의 단위 개수를 알아보았으며, 그 결과 은닉층은 총 50개의 단위로 구성되었다.

또한 출력층에는 정화층(clean-up layer)이 10개 단위로 구성되어 있다. 이 층이 존재하는 데는 두 가지 이유가 있다. 첫째로, 정화 과정(clean-up)을 통해 모델의 성능 개선이 가능하기 때문이다. 모델의 일반적인 학습 단계에서는 출력층 내의 단위들 간의 상호작용을 가능하게 함으로써, 활성화 값이 0 혹은 1의 목표값에 안정적으로 도달하도록 어트랙터(attractor)를 형성한다(Hinton & Shallice, 1991; Hutzler, Ziegler, Perry, Wimmer, & Zorzi, 2004; Plaut & Shallice, 1993; Plaut, 1999). 두 번째 이유는, 기억이라는 인지 능력의 모사가 가능해

지기 때문이다. 현재 있는 출력층의 활성화 정보를 재귀적으로 자신에게 재입력하는 정화층은 일종의 작업 기억의 역할을 담당한다. 특히 본 연구에서 사용된 과제 중 하나인 의미 점화 어휘 판단 과제를 모사한 모델용 과제를 수행함에 있어서, 점화 자극의 활성화 값을 일시적으로 보관하는 역할을 수행한다.

그밖에, 학습에 요구되는 변수인 가속도(momentum)는 0.9, 감쇠율(decay rate)은 1×10^{-6} 로 설정되었고, 각 단위들 간의 연결인 연결의 초기 가중치는 -1 에서 1 사이에서 무작위로 할당되었다.

본 연구에서는 이와 동일한 구조의 모델을 총 8개 구성하였고, 각 모델은 독립적으로 이후 언급될 학습과 과제를 수행하였다. 이는 각각의 모델을 하나의 참여자로 할당하여, 과거 연구들에서 나타났던 통계적인 한계점을 극복하기 위함이었다.

본 연구의 모델링은 Microsoft Visual Studio 2015 Community 프로그램을 이용하여 C# 언어를 통해 이루어졌고, Intel i7-4770K 프로세서와 16,384MiB 램, Windows 10 64-bit 운영체제인 컴퓨터에서 모델의 학습 및 과제가 수행되었다.

	주체	장소	사람	직업	전문직	학생	...	호칭	직원	...	교사	지위	...
학생	1	0	1	1	1	1	...	1	0	...	0	0	...
교사	1	0	1	1	1	0	...	0	1	...	1	1	...

그림 3. 출력층의 표상 예시. 상단은 '학교'라는 개념에 대한 표상이고, 하단은 '교사'라는 개념에 대한 표상이다. 각 출력단위(output unit)는 하나의 의미 속성(semantic feature)을 표현하게 된다. 개념이 단위에 할당된 표상을 보유하고 있을 경우, 해당 단위는 1의 활성화 값을 갖게 되며, 나머지 단위들은 모두 0을 갖는다.

자극 모델의 학습에 사용된 각 단어자극은 한국과학기술원 전문용어언어공학연구소(2005)가 제안한 CoreNet의 1-3음절 명사 중에서 추출되었다(한국과학기술원 전문용어언어공학연구소, 2005). CoreNet은 개념정보를 구성하는 속성과, 각 철자 단어가 어떤 속성을 보유하고 있는지에 관한 정보를 제공한다. 그리고 CoreNet이 제공하는 속성들을 위계적인 트리 구조로 나타낸다. 그리고 각 속성은 코텀(cotham)이라 불리는 트리 구조 상에서의 위치 정보를 가지고 있다. 가령 최상위에 해당하는 구체/추상(1)에 대하여, 1 뒤에 1과 2가 각각 붙어서 ‘구체(11)’, ‘추상(12)’의 의미 속성을 나타낸다. ‘구체(11)’ 속성은 다시 ‘주체(111)’, ‘장소(112)’, ‘물건(113)’ 등과 같은 하위의 의미 속성으로 이어진다. 이와 같은 형태로 각 속성들이 트리 구조를 가지며, 하나의 개념은 복수의 속성을 보유하게 된다.

본 연구에서는 출력층의 과도한 증가로 인한 학습시간 증가를 막기 위해, ‘구체(11)’의 하위인 992개의 속성만을 사용하여, 단어의 의미 정보를 표현하였다. 이에 따라 ‘추상(12)’ 이하의 속성은 제외되었으며, 오직 추상 이하의 속성만을 가지고 표현되는 단어 또한 자극에서 제외되었다.

속성을 기준으로 제외된 단어들 중 동형이의어(homograph)의 경우, Ziegler, Perry & Coltheart(2000)을 참고하여 하나의 단어가 동형이의어 전체의 모든 속성을 갖고 있도록 하였다. 이는 동형이의어가 제시되었을 때, 참여자가 해당하는 단어 전부를 표상한다는 과거 연구를 반영하기 위함이다(나운혜, 2014; Ziegler, Perry, & Coltheart, 2000).

위의 과정을 통해 최종적으로 학습을 위한 10,372개의 자극을 구성하였다.

또한 모델의 과제 수행을 위해 총 5 종류의 자극 목록을 구성하였다. 학습되지 않은 자극으로부터 유의미한 개념을 산출해내는 것은 불가능하므로, 자극 목록에서 비단어를 제외한 모든 자극들은 학습된 자극 10,372개 중에서 조건에 맞는 자극을 무작위로 선택하였다.

첫 번째 목록은 학습을 위해 추출된 단어 10,372개 전부였으며, 이 목록은 학습의 진행 상황에 따른 모델의 학습 정도를 파악하기 위하여 사용되었다. 두 번째 목록은 빈도 효과(frequency effect)를 확인하기 위한 목록이었다. 빈도 효과를 파악하기 위해 2음절 단어 중에서 학습 확률 0.8에서 0.6 사이의 단어를 고빈도로, 0.3에서 0.1 사이의 단어를 저빈도로 정의하였으며, 조건에 해당하는 단어 중, 각각 150개씩을 무작위로 추출하여 구성하였다. 세 번째 목록은 단어 유사 효과(word similarity effect)를 확인하기 위한 목록으로, 두 종류의 비단어(pseudo-word와 nonword)를 각각 100개씩 제작하여 구성하였다. 여기서 pseudo-word는 학습에 사용된 단어에 포함되어 있는 음절들의 조합으로 구성된 비단어였고, nonword는 학습에 사용되지 않은, 즉 모델에 한 번도 노출되지 않은 음절들의 조합으로 구성된 비단어였다. 네 번째 목록은 의미 충실도 효과(semantic richness effect)를 검증하기 위한 목록으로, 2음절 단어 중 0.5에서 0.6 사이의 학습 확률인 단어 중에서 속성을 20개 이상 보유하고 있는 단어를 다속성(richness)으로, 10개 이하로 보유하고 있는 단어를 소속성(poorness)으로 정의하였으며, 조건에 해당하는 단어 중 각각 100개

씩을 무작위로 추출하여 구성하였다. 마지막 목록은 의미 점화 효과(semantic priming effect)를 확인하기 위한 자극쌍 목록으로, 학습 확률 0.4와 0.6 사이이며 속성을 15개 이상 보유하고 있는 2음절 단어 중, 다음의 공식을 기준으로 0.7 이하인 경우(속성이 5개 이하 다름)를 관련 조건(related), 0.85 이상인 경우(속성이 33개 이상 다름)를 무관련 조건(unrelated)으로 정의하였으며, 조건에 해당하는 자극 쌍 중 각각 40개씩을 무작위로 추출하여 구성하였다.

$$D = 1 - \frac{1}{1 + \sqrt{\sum (T_{li} - T_{ri})^2}}$$

위의 수식 중 $\sqrt{\sum (T_{li} - T_{ri})^2}$ 는 유클리드 거리(Euclidean distance)를 구하는 공식이다. 수학적 의미에서 유클리드 거리는, N차원에 대한 두 개체 간 유클리드 거리는, 각 차원이 다를수록 점차적으로 그 크기가 증가하게 된다. 단어를 개체로, 속성 각각을 하나의 차원으로 놓을 경우, 모든 단어는 서로 간의 유클리드 거리를 구할 수 있고, 이 거리가 단어 간의 의미 관계성을 나타낸다고 할 수 있다 (Frank, Haselager, & van Rooij, 2009; Vigliocco & Vinson, 2007). 본 연구에서는 유클리드 거리를 응용하여 두 자극의 거리를 0과 1사이의 수치로 계산하였다.

학습 학습은, 구성된 10,372개의 자극 전체를 여러 세대 동안 반복적으로 제시하고, 출력층에 표상된 패턴 상의 오류를 수정하는 과정을 통해 이뤄졌으며, 구체적으로는 다음과 같다.

- 1) 자극 목록 전체의 순서를 무작위로 섞어, 학습 순서를 결정한다.
- 2) 순서에 따라 선택된 단어의 학습 확률에 의해, 해당 단어의 학습 여부를 결정한다. 각 단어의 학습 확률은 McClelland & Seidenberg (1989)를 참조하여, 각 자극 i 에 대하여 다음 공식을 통해 계산되었다(Seidenberg & McClelland, 1989).

$$P_i = 0.15 \times \log_{10}(F_i + 2)$$

P 는 학습 확률을 의미하고, F 는 빈도를 의미한다. 이 공식에 의해 최고 빈도와 최저 빈도 단어의 학습 확률은 각각 94.63% 와 4.52%로 계산되었다.

- 3) 단어가 학습되기로 결정되었다면, 피드포워드 과정 및 출력층에서의 정화 과정을 통해 해당 단어에 대한 모델의 출력층의 활성화 값을 결정한다. 한편 학습되지 않기로 결정되었다면 다음 단어로 넘어간다.

- 4) 아래의 공식을 이용하여 각 출력 단위의 활성화 값과 목표값을 비교하여 오류를 계산한다.

$$ErrorRate_i = \sum (T_i - A_i) \times Sigmoid'(S_i)$$

T 는 해당 단위의 목표값(target values)으로, 자극에 따라 0 혹은 1을 가지며, A 는 해당 단위의 실제 활성화 값(activation values)을 의미한다. S 는 하위층인 은닉층의 각 단위에서 보내져서 합산된 활성화 입력값을 의미한다.

- 5) back-propagation 알고리즘을 통해, 각 층들을 연결하는 연결들의 가중치를 수정한다.

이때 가중치 수정 공식은 다음과 같다.

$$W_{n+1} = W_n + [(T_r \times ALR + (1 - T_r) \times DLR) \times ER_r \times A_s]$$

W 는 가중치를, ALR 은 가중치가 증가하는 경우의 학습률을, DLR 은 가중치가 감소하는 경우의 학습률을 의미한다. 또한 각 첨자의 r 과 s 는 각각 해당 연결을 기준으로 했을 때, 값을 보내는 단위와 값을 받는 단위를 의미한다. 이 수정 공식은, 종래 연결주의 모델에서 사용되던 공식,

$$W_{n+1} = W_n + (LR \times ER_r \times A_s)$$

와는 다르게 가중치가 증가하는 경우와 감소하는 경우의 학습률이 다르다. 이에 대해서는 두 가지 이유가 있다. 하나는 신경학적인 이유로서, 신경학적으로 외현기억의 구성에 영향을 미치는 메커니즘이 나뉘어 있기 때문이다. ALR 에 해당하는 메커니즘인 장기강화(long term potentiation)는 신경세포들의 동시적 자극에 의한 시냅스 간 연결을 강화시키는 방식으로, 장기강화가 진행될수록 신호 전달에 의한 활성화 정도가 증대된다. 반대로 DLR 에 해당하는 메커니즘인 장기저하(long term depression)는 활성화에 영향을 끼치지 못하는 시냅스의 연결을 약화시킴으로써, 신호 전달에 의한 활성화 정도를 감소시킨다. 이 두 메커니즘은 학습 과정에 있어서 상호 보완적으로 작용하여, 자극에 대한 시냅스 활성화 정도를 변화시킴으로써, 기억을 구성하게 된다 (Morris, 2004; Siegelbaum & Kandel, 2013; Thomas & Malenka, 2004). 나머지 하나는 연결

주의 모델의 메커니즘 단계의 이유로서, 대단위의 학습 단어의 사용이 문제가 된다. 본 모델은 1세대(epoch) 당 평균적으로 3,500-4,000회의 단어를 학습하지만, 각 단어를 학습 할 때 출력층 단위의 목표값은 대부분의 경우 0이다. 이에 대해서 매 학습마다 오류 감소를 시도하는 연결주의 모델은, 모든 단위가 항상 0을 출력하는 상황이 가장 정답에 근접할 것으로 예측하기 때문에, 결과적으로 어떤 속성도 활성화하지 않는 방향으로 학습을 시도한다. ALR 과 DLR 의 구분은 이런 문제를 해소시켜 주며, 동시에 실제 인간의 신경학적 기반과의 유사성을 확보하게 해 준다.

6) 각 층들을 연결하는 연결의 가중치를 제외한 나머지를 초기화하고 2)로 돌아가 다음 단어의 학습을 시도한다.

위의 과정을 1세대로 진행하며, 학습은 총 1,000세대동안 진행되었다.

과제 시뮬레이션 학습이 종료된 후, 모델은 위에서 언급된 1,2,3,4번 자극 목록에 대하여 어휘판단과제(lexicon decision task)를, 5번 자극 목록에 대하여 의미점화 어휘판단과제(semantic priming lexical decision task)를 시뮬레이션 하였다. 어휘판단과제 수행 과정은 학습 과정과 유사하였다. 다만 본 연구에서는 과제 수행 중의 학습 현상은 고려하지 않았기 때문에 학습 과정에서 포함되어있던 가중치를 수정하는 과정은 과제 수행에서는 제외되었다. 의미점화 어휘판단 과제에서는, 1차적으로 점화자극에 해당하는 자극에 대하여 정화 과정 직전까지의 과정을 수행하였다. 단, 출력층에서 정화층으로 활성화 값이 전달된 상황에서 이후 과

정을 중단하고, 입력층, 은닉층, 출력층의 값은 초기화되었다. 그리고 2차적으로 목표자극에 해당하는 자극에 대하여 일반적인 어휘 판단과제와 동일한 과정이 진행되었다. 이를 통해 정화 과정에서는 점화자극에 의한 활성화 값과 목표자극에 의한 활성화 값이 같이 처리되도록 하였다.

과제 수행에 대한 평가 지표는 Hinton & Shallice(1991)이 제시한 교차 엔트로피(cross entropy)와 Plaut et al.(1996)에서 제시한 의미 강조값(semantic stress)이 사용되었으며, 교차 엔트로피는 다음과 같은 공식으로 계산되었다(Hinton & Shallice, 1991; Plaut, McClelland, Seidenberg, & Patterson, 1996).

$$Cross\ Entropy = -\frac{1}{n} \sum ((T_i \times \log_e A_i) + (1 - T_i) \times \log_e (1 - A_i))$$

교차 엔트로피는 각 출력 단위의 오류가 적을수록 감소하며, 0에 접근한다. 모델은 50세대의 학습이 종료될 때마다 자극목록 1을 이용하여 교차 엔트로피를 측정함으로써, 학습 진행 상황을 표시하였다(Hinton & Shallice, 1991).

또한, 의미 강조값은 다음 공식으로 계산되었다.

$$Semantic\ Stress = \frac{1}{n} \sum ((A_i \times \log_2 A_i) + (1 - A_i) \times \log_2 (1 - A_i) + 1)$$

의미 강조값은 각 출력 단위의 크기가 양극단(0 혹은 1)에 가까워질수록 증가하며, 1에 접근한다. 이는 모델이 각 속성에 대해 명확한 표상이 가능할수록, 의미 강도가 증가함을 의미한다(Plaut, 1997; Yim et al., 2005).

결 과

서론 및 방법 절의 모델링 구조 부분에서 언급한 바와 같이, 과거 연구들은 단일 모델의 시뮬레이션 결과를 토대로 도출된 자극을 하나의 표본으로 삼아 통계분석을 함으로써, 과도한 자유도를 얻게 되고 이로 인해 결과가 왜곡될 가능성이 존재하였다. 본 연구는 과거 모델링 연구들의 통계분석상의 제한점을 극복하기 위해 학습 및 과제를 수행한 모델 하나가 하나의 참여자로 가정되어 총 8명의 참여자를 대상으로 수행한 것과 같은 방식으로 진행되었다. 무작위로 할당된 초기 연결 강도와, 학습 중 각 세대의 학습 순서의 무작위성 및 학습 확률에 따른 학습 불규칙성은, 참여자 개인의 개인 차이를 반영하고, 동일한 모델 구조는 한 집단의 참여자는 동일하다는 통계적 가정을 충족시킨다.

학습 진행간 교차 엔트로피 변화 그림 4는 모델의 교차 엔트로피의 흐름을 보여준다. 그림에 따르면, 총 1,000세대의 학습을 진행하는 동안, 100세대 지점에서 이미 교차 엔트로피가 안정되었음을 보여주었다. 이는 모델이 의미 표상을 정상적으로 학습하였음을 제시한다.

빈도 효과 모델의 빈도 효과에 대해 알아보기 위해 대응표본 t-검정을 실시하였다. 검정 결과, $p < 0.001$ 수준에서 유의하게 고빈도 범주의 단어 목록이 저빈도 단어 목록보다 의미 강조값이 높았다($t(7) = 12.056, p < 0.001$). 이는 과거의 행동실험에서 나타나는 빈도 효과를 모델이 모사하였음을 나타낸다. 그림 5는

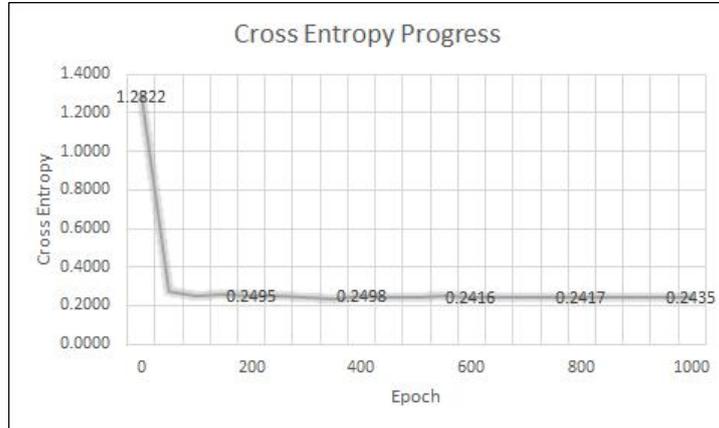


그림 4. 학습 과정 중의 교차 엔트로피 변화 흐름. 모델이 100세대 시점에 도달한 교차 엔트로피 지점에서 큰 변화 없이 안정되어 있음을 보여준다. 이 결과는, 각 출력 단위의 오류가 적을수록 감소하는 교차 엔트로피의 특성에 비추어 생각할 때, 모델이 100세대 시점에 이미 학습이 어느 정도 종료되었음을 의미한다.

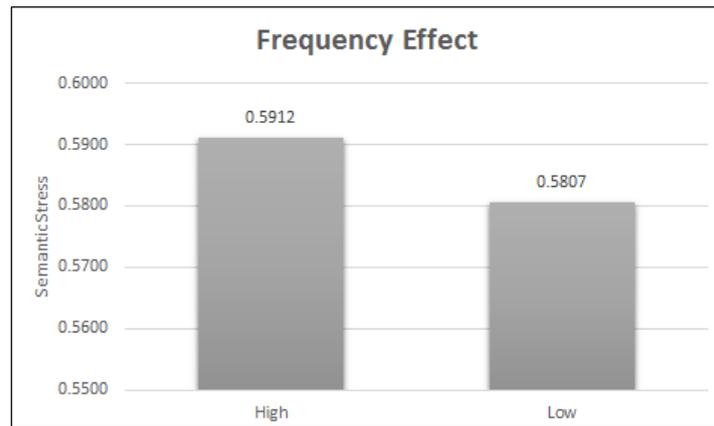


그림 5. 고빈도 자극(high)과 저빈도 자극(low)의 차이. 모델은 고빈도 자극에서 유의하게 더 높은 의미 강조값(semantic stress)을 산출하였다. 의미 강조값이 높을수록 더 짧은 반응시간(reaction time)을 의미하며, 이 결과는 모델이 빈도 효과를 효과적으로 시뮬레이션 하였음을 의미한다.

빈도에 따른 의미 강조값의 차이를 보여준다.

단어 유사성 효과 단어 유사성 효과에 대해 알아보기 위해 대응표본 t-검정을 실시하였다. 검정 결과, $p < 0.001$ 수준에서 유의하게

pseudo-word 범주의 단어 목록보다 nonword 목록이 의미 강조값이 높았다($t(7) = 11.834, p < 0.001$). 이는 행동실험에서 단어에 유사한 비단어일수록 과제 수행이 떨어지는 단어 유사성 효과를 모델이 모사하였음을 보여준다. 그

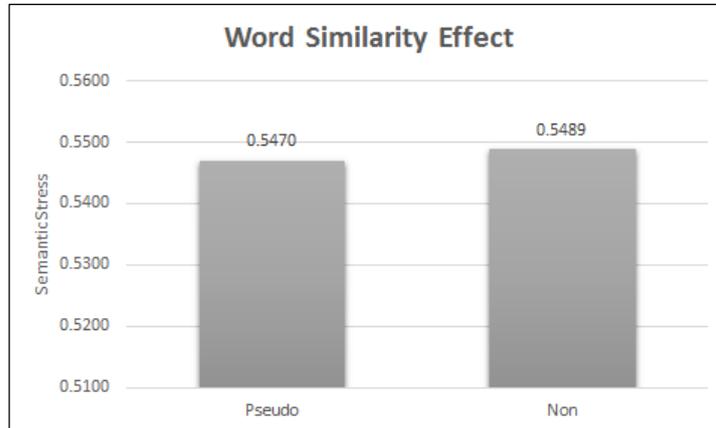


그림 6. 비단어 pseudo-word와 nonword의 차이. 모델은 nonword 자극에서 유의하게 더 높은 의미 강조값(semantic stress)을 산출하였다. 이 결과는 모델이 단어 유사성 효과를 효과적으로 시뮬레이션 하였음을 의미한다.

그림 6은 속성의 차이에 따른 의미 강조값의 차이를 보여준다.

의미 충실도 효과 의미 충실도에 대해 알아보기 위해 빈도 효과와 마찬가지로 대응표본 t-검정을 실시하였다. 검정 결과, $p < 0.001$ 수준

에서 유의하게 다속성 범주의 단어 목록이 소속성 단어 목록보다 의미 강조값이 높았다 ($t(7) = 12.053, p < 0.001$). 이는 과거의 행동 실험에서 나타나는 의미 충실도 효과를 모델이 모사하였음을 나타낸다. 그림 7은 속성의 차이에 따른 의미 강조값의 차이를 보여준다.

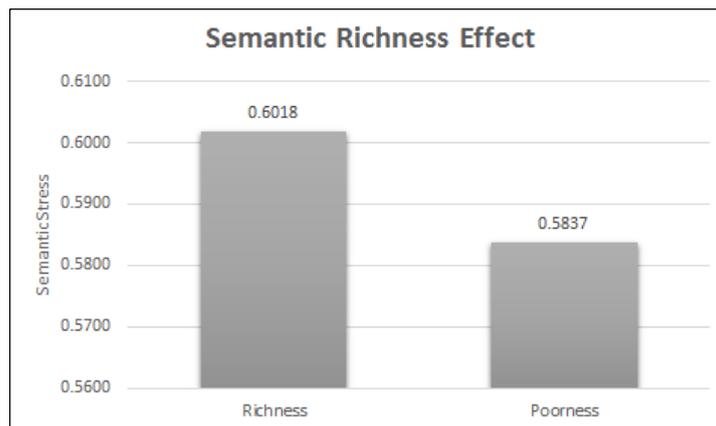


그림 7. 다속성(richness) 조건과 소속성(poorness) 조건의 차이. 모델은 다속성 조건에서 유의하게 더 높은 의미 강조값(semantic stress)을 산출하였다. 이 결과는 모델이 의미 충실도 효과를 효과적으로 시뮬레이션 하였음을 의미한다.

Hudson & Bergman, 1985; Kwon & Lee, 2014; Kwon, Park, Lim, Jung, & Nam, 2006).

단어 유사성 효과 단어 유사성 효과의 경우 pseudo-word와 nonword는 양쪽 모두 학습된 적이 없는 비단어이며, 그에 따라 의미 정보와의 연결성이 없다. 그렇다면 왜 두 조건은 동일한 결과를 도출하지 않고, nonword에서 더 큰 활성화가 나타나는가? 이에 대한 가장 가능성이 높은 설명은, 철자 표상과 의미적 속성 표상간의 부분적 연결성을 들 수 있다. 가령 ‘학교’ 라고 하는 단어를 학습할 때, 모델은 ‘학교’ 전체적인 패턴뿐만 아니라, ‘학’과 ‘교’와 같은 부분적인 철자 표상과 의미표상간의 연결이 영향을 받게 된다. 이와 같은 현상은 ‘학원’과 같은 다른 자극의 학습 시에도 나타나게 되고, 결과적으로 ‘학’ 음절의 입력 패턴이 출력 패턴에 일부 영향을 끼치게 된다. 문제는, pseudo-word가 이와 같은 음절이 포함된 비단어라는 점이다. 단어였다면 각각의 음절 모두, 그리고 조합된 전체 패턴에 의해 출력층의 단위들이 정상적으로 활성화되었겠지만, pseudo-word에 포함되어 있는 음절들은 각각 잠재적으로 관련될 수 있는 의미의 출력층의 패턴에 경쟁적으로 기여하게 된다. 의미 강조값은 각 단위들이 명확하게 0이나 1에 접근할수록 증가하게 되므로, 이런 활성화/억제는 오히려 양 극단(특히 0)에서 멀어지도록 만들고, 결과적으로 nonword보다 의미 강조값이 감소하게 된다.

의미 충실도 효과 Pexman et al. (2008) 은 어휘판단과제 상에서 의미 충실도의 효과에 대

해, 속성의 수가 많을 경우 더 강한 의미 활성화를 이끌어내고, 이 활성화가 철자 정보에 피드백 됨으로써 나타난다고 이야기하였다 (Pexman, Hargreaves, Siakaluk, Bodner, & Pope, 2008; Pexman, 2012; Yap, Tan, Pexman, & Hargreaves, 2011). 하지만 본 모델은 재귀적 (recurrent)으로 출력값이 입력값에 영향을 주는 구조가 구성되지 않았음에도 여전히 의미 충실도 효과가 나타났다.

우리는 본 모델이 어떤 형태로 의미 충실도의 차이가 나타났는가를 알아보기 위하여, 각 출력 단위의 활성화값을 확인하였다. 분석 결과, Pexman et al. (2008)이 제시와는 다르게, 목표값이 1인 단위들의 활성화값($t(7) = 24.068$, $p < 0.001$), 목표값이 0인 단위들의 활성화값($t(7) = 28.111$, $p < 0.001$), 그리고 전체 활성화 값($t(7) = 10.107$, $p < 0.001$) 모두에서 소속성 조건 출력 단위들의 활성화가 높았다. 이를 통해 알 수 있는 점은, 소속성 조건에서의 출력 단위들 중 목표값이 0인 단위들이 과도하게 활성화됨으로써 의미 강조값이 더 낮게 나오게 되었고, 이에 따라 다속성 조건이 상대적으로 더 높은 의미 강조값을 도출하게 되었다고 볼 수 있다.

그렇다면, 왜 다속성에서 전반적인 활성화 감소가 나타났는가? 본 연구는 이에 대해, 다속성과 소속성 조건이 보유하고 있는 속성들의 속성 트리 상의 분포에 그 원인이 있을 것으로 본다. 자극에서 언급한 것처럼, CoreNet은 단어의 속성을 트리 구조로 표현한다. 이는 달리 말하면, 어떤 개념이 하위 속성을 보유하고 있을 경우, 해당 속성의 상위 속성 또한 보유하고 있을 가능성이 높아지게 된다는

것을 의미한다. 다속성 조건의 경우, 트리 구조로 엮이지 않는 독립적인 속성을 여러 개 가지고 있을 경우도 있지만, 다른 한 편으로 훨씬 더 하위 속성을 보유하게 됨으로써 트리 구조 상의 상위에 해당하는 속성까지 보유함으로써 속성의 개수가 증가한 경우도 있다. 이에 대해 검증해보기 위해, 다속성 자극과 소속성 자극이 보유하고 있는 속성들의 트리 구조상의 깊이(tree depth)의 평균을 확인해보았다. 그리고 확인 결과, 다속성 6.184(SD: 0.3784), 소속성 5.271(SD: 0.8140)로 두 조건 간에 보유한 속성들의 평균 깊이가 다른 것을 확인할 수 있었다. 그리고 이 차이는, 소속성 조건에서 목표값이 1인 단위들의 활성화값이 유의하게 더 높은 이유가 된다. 소속성 조건이 보유한 속성들은 전반적으로 트리 구조의 상위에 위치한 속성들이기 때문에, 자극 목록 전체에서 빈번하게 목표값 1인 상황에 놓였을 것으로 추측할 수 있다. 하지만, 다속성 조건의 경우 트리 구조의 상위뿐만 아니라 중위나

하위에 위치한 속성들, 즉 깊이가 깊은 속성들도 보유하고 있으며, 이들은 해당 자극을 제외하면 목표값이 1인 상황이 매우 드물다. 이에 따라, 다속성 조건에서 깊이가 얇은 속성은 소속성 조건의 속성들처럼 활성화가 일어났으나, 깊이가 깊은 속성들이 얇은 속성만큼의 활성화를 일으키지 못함으로써, 전체적인 목표값 1인 단위들의 평균들을 떨어뜨렸다. 이에 관해 검증해보기 위해, 각 속성 깊이와 전체 학습 자극 목록에서 해당 속성이 포함되어 있는 값을 구한 뒤, 속성 깊이 별 평균을 내 보았다. 그림 9는 그 결과이다. 추측한 바와 같이, 깊이가 증가할수록 속성의 평균 사용 정도가 감소하였다. 비록 각 자극의 학습 확률이 다르기 때문에, 온전하게 각 자극의 비중을 1로 할당하는 계산엔 제한점이 있지만, 그럼에도 불구하고 깊이에 따른 속성 사용 정도가 다름을 확인할 수 있다. 우리는 이를 통해, 다속성에서 목표값이 1인 단위들의 활성화값이 유의하게 더 낮은 이유를 확인할 수

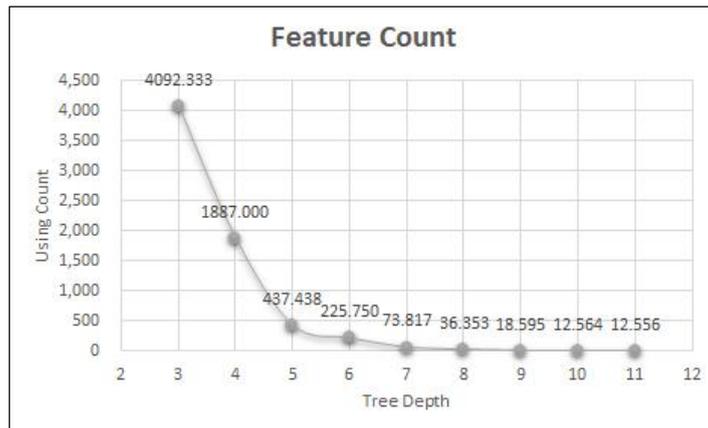


그림 9. 속성 깊이 별 속성의 사용 정도. 가로축은 트리 구조상의 깊이(tree depth)를, 세로축은 해당 깊이에 해당하는 속성들이 학습자극들에 포함되어 있는 정도에 대한 평균을 의미한다. 깊이가 증가할수록 포함되어 있는 정도가 기하급수적으로 감소한다.

있었다.

이와 같은 속성 트리 상의 분포는, 목표값이 0인 단위들에서도 소속성 조건에서 더 높은 활성화가 나온, 그래서 목표값이 1인 단위에서 더 낮은 활성화를 보였음에도 결과적으로 다속성 조건이 의미 강조값이 높아진 데에 대한 원인이 될 수 있다. 그림 9에서 제시된 것처럼, 9 이상의 가장 깊은 하위 수준에 위치한 속성들의 경우, 다속성 조건과 소속성 조건 모두에서 높은 확률로 목표값이 0이 할당되게 된다. 이 경우 위에서 언급한 3이나 4 처럼 얕은 수준의 깊이를 가진 속성이 빈번하게 목표값이 1이 되는 것 이상으로 빈번하게 목표값이 0이 된다. 따라서 이들은 다속성 조건과 소속성 조건 모두에서 균일하게 낮은 활성화값을 보일 것이다. 하지만, 5나 6과 같은 중간 수준의 깊이를 가진 속성들은 그렇지 않다. 이들은 다속성 조건에서는 목표값이 1인

경우가, 소속성 조건에서는 목표값이 0인 경우가 많게 되고, 그 결과 얕은 수준의 깊이를 가진 속성보다는 목표값이 0인 경우가 많지만, 극단적으로 0에만 몰려 있는 것은 아니다. 물론 그림에도 불구하고 전체 자극 중에서는 목표값이 0인 경우가 훨씬 많다. 그럼에도 이 깊이 수준의 자극들이 핵심적인 차이를 만들어낼 수 있는가? 이에 대해, 추가적으로 고려해야 하는 부분이 학습에서 언급한 ALR과 DLR이다. 본 연구에서 모델 내의 가중치는 활성화되는 방향으로 변화할 때는 0.5, 억제되는 방향으로 변화할 때는 0.001로 할당되었다. 이 두 학습률의 차이는, 해당 단위의 목표값이 1일 경우 변화량을 크게 증가시키게 된다. 이 가중치를 적용하였을 때, 전체 속성 깊이 i 별 속성값 변경 방향성은 다음과 같은 공식으로 구해지게 되며, 그 결과는 그림 10과 같다.



그림 10. 속성 깊이 별 방향성. 가로축은 트리 구조상의 깊이(tree depth)를, 세로축은 세대가 흐를수록 해당 깊이에 해당하는 속성들이 어느 방향으로 움직이는가를 나타낸다. 세로축의 +와 - 기호는 세대의 흐름에 따라, 해당 깊이가 점차 어느 방향으로 움직이는가를 나타내며, 강도(strength)는 세대를 거치면서 얼마나 빠르게 활성화가 증가될 수 있는지를 나타낸다. 이에 따르면, 깊은 수준의 속성들은 - 방향으로 움직이는 반면, 얕은 수준과 중간 수준의 속성들은 + 방향으로 움직인다.

$$Direction.Strength_i = ALR \times FC_i + DLR \times (TS - FC_i)$$

시뮬레이션에서 언급한 바와 같이, ALR은 가중치가 증가하는 경우의 학습률을, DLR은 가중치가 감소하는 경우의 학습률을 의미한다. FC는 각 속성이 사용된 정도를 의미하며, TS는 전체 학습 자극의 숫자를 의미함으로써, 본 연구에선 10372가 할당되었다. 이와 같은 속성 깊이 별 방향성은, 한 세대가 지날 때마다, 해당하는 방향(+, -)으로 움직이게 될 것으로 추측할 수 있다. 이를 통해 살펴보면, 예측대로 가장 하위 수준의 깊이를 갖는 위치한 속성들의 경우 -의 방향성을 가지는 반면, 나머지 얕은 깊이와 중간 수준의 깊이를 가진 속성들은 +의 방향성을 갖게 된다. 위에 언급한 바와 같이, 중간 수준의 깊이를 가진 속성들은, 다속성 조건에서는 목표값이 1이 될 가능성이, 소속성 조건에서는 목표값이 0이 될 가능성이 높다. 이에 따라, 점차 다속성 조건에서는 목표값이 1인 단위들의 활성화 증가에, 소속성 조건에서는 목표값이 0인 단위들의 활성화 증가에 영향을 끼치게 되고, 위와 같이 모든 단위가 소속성 조건에서 오히려 활성화가 증가하는 현상이 나타나게 된다.

그리고, 이와 같은 모델이 진행되는 방향성과 해당 자극이 목표로 하는 방향성의 차이에 의해, 소속성 조건이 의미 강조값이 감소하게 된다. 즉, 모델링의 학습은 깊이 기준으로 봤을 때, ‘얕은 속성: 증가, 중간 속성: 증가, 깊은 속성: 감소’를 추구한다. 이에 대해 다속성 자극은 모델링의 학습과 일치되게 ‘얕은 속성: 증가, 중간 속성: 증가, 깊은 속성: 감소’를 지향하는 반면, 소속성 자극은 ‘얕은 속성: 증가,

중간 속성: 감소, 깊은 속성: 감소’를 지향함으로써 깊이가 중간 수준인 속성들에서 충돌이 일어나고, 그 결과로 의미 강조값이 감소하게 된다고 할 수 있다.

의미 점화 효과 의미 점화 효과가 나타나는 메커니즘의 핵심은 활성화의 추가라고 할 수 있다. 의미 점화 효과에서, 관련 조건에 사용되는 점화자극과 목표자극은, 무관련 조건에 비교하여 상대적으로 많은 속성들을 공유하게 된다. 이는 점화 자극이 제시됨으로써 활성화되는 출력 단위들은, 목표 자극에서도 활성화되어야 할 단위일 가능성이 높다는 것을 의미한다. 즉 관련성이 높은 점화 자극의 경우, 목표 자극과 관련되는 속성, 다시 말해서 1이 목표값인 단위들을 선행적으로 활성화 시키게 되고, 이로 인해 무관련 조건에 비해 더 높은 활성화를 얻게 된다. 이 메커니즘의 타당성에 대해 확인하기 위해, 관련조건과 무관련조건 간의 목표값이 1인 단위들의 활성화값을 비교 분석하였고, 분석 결과 관련조건에서 더 높은 활성화값이 나타났다($t(7) = 20.945, p < 0.001$).

의미 관계성의 정의 제시된 결과에 의하면 모델은 정상적으로 점화 효과를 나타냈고, 이는 유클리드 거리가 제대로 의미적 연관성을 반영했음을 보였다고 판단된다. 하지만, 문제는 그 방안이다. 서론에서 언급한 것과 같이, 전체론적 관점의 의미 표상 구조는 의미 간의 관계성에 초점을 맞추고, 서로 다른 의미 간의 연결성을 제시하는 반면, 속성적 관점은 구조 내에 의미 간의 연결성이 표시되지 않으

므로 그 관계성을 제시하기 어렵다. 기본적으로 겹침(overlap)에 의한 유사성에 기반한 관계인 유클리드 거리가, 실제 언어에서의 다양한 의미간 관계성을 어떻게 제대로 표현해 낼 수 있는가 하는 가에 대한 논의가 필요하다.

기본적으로 유의어는 많은 선행 연구 및 의미적 관련성에 대한 전제에 의해 비슷한 형태로 표현이 가능하다. ‘노예’와 ‘농노’는 분명 관련된 의미를 지니지만, 서로 다른 언어이다. CoreNet 기준으로 ‘노예’에는 천민, 노동자, 고용인과 같은 속성으로, ‘농노’에는 천민, 노동자, 농민과 같은 속성으로 구성되어 있으며, 고용인과 농민은 ‘직업’의 속성까지는 동일하다(표 1).

그렇다면 어째서 종속어와 반의어가 겹침에 의해서 표현될 수 있는가? 이는 실재론 유사

어 만이 아니라 종속어와 반의어 또한 많은 속성이 겹친다는 점이 고려되어야 한다. 예를 들어 실제 언어 의미적으로 단어 ‘식품’과 ‘야채’간의 관계는 ‘식품’이 ‘야채’를 포함하는 종속 관계이다. 이 경우 ‘야채’라는 개념은, ‘식품’을 표상하는 속성에 ‘야채’를 의미하는 속성이 추가적으로 더 들어가게 되는 구조이고, 따라서 ‘야채’의 많은 속성들은 이미 ‘식품’에도 포함되어 있는 속성이라는 것을 의미한다. 결과적으로, 상위어인 식품에 존재하는 속성들은 하위어인 야채에서도 존재하므로 유클리드 거리에 영향을 끼치지 못하고, 오직 야채에만 추가되어있는 속성들만이 두 단어 간의 유클리드 거리가 생기는 원인이 된다(표 1). 그에 따라, 다른 비관련 조건에 비해 상대적으로 짧은 유클리드 거리를 지니게 되어, 의

표 1. 각 관계별 속성 보유 비교에 대한 예시.

단어	종속어 관계		유의어 관계		반의어 관계	
	식품	야채	노예	농노	왼쪽	오른쪽
공유 속성	<ul style="list-style-type: none"> · 구체 · 물건 · 무생물 · 인공물 · 식료 · 식품 	<ul style="list-style-type: none"> · 구체 · 물건 · 무생물 · 인공물 · 식료 · 식품 	<ul style="list-style-type: none"> · 구체 · 노동자 · 사람 · 사람 · <직업/지위/역할> · 사람<직업> · 인간 · 인간<노자> · 인간<사회계층> · 인간<사회집단> · 인간<신분> · 주체 · 천민 	<ul style="list-style-type: none"> · 구체 · 노동자 · 사람 · 사람 · <직업/지위/역할> · 사람<직업> · 인간 · 인간<노자> · 인간<사회계층> · 인간<사회집단> · 인간<신분> · 주체 · 천민 	<ul style="list-style-type: none"> · 추상 · 추상적관계 · 장소 · 좌우 	<ul style="list-style-type: none"> · 추상 · 추상적관계 · 장소 · 좌우
비공유 속성		<ul style="list-style-type: none"> · 야채 · 생물 · 식물 · 식물(개체) · 풀 · 작물 	<ul style="list-style-type: none"> · 고용인 · 사람(서비스직) 	<ul style="list-style-type: none"> · 농민 · 사람(농립어업) 	· 왼쪽	· 오른쪽

미적 관련성이 형성되게 된다.

같은 형태의 논리가 반의어에도 적용될 수 있다. 실제 의미적으로 반대의 의미인 두 단어의 유클리드 거리는 대부분의 경우 매우 짧다. 이는 어떤 반대되는 두 단어가 실제로는 동일한 하나의 차원 내에서 위치하고 있기 때문이다. ‘왼쪽’, ‘오른쪽’은 서로 반대 방향을 가리키는 반의어에 해당하지만, 이는 어떤 방향이라는 점까지는 동일한 속성을 공유하게 된다(표 1). 즉, 반의어의 대립을 형성하기 위한 대부분의 속성은 동일하고, 이 둘의 방향성을 결정하는 몇몇 속성만이 서로 다를 경우에 반의어관계가 형성이 된다. 따라서 반의어는 사실 유의어와 매우 비슷한 형태로 서로 간의 의미 관계성을 형성한다고 할 수 있다.

과거 모델링 연구와의 비교 본 연구가 제시한 모델은 속성적 관점을 적용한 개념 표상을 사용하여, 의미 정보 처리 과정을 보였다는 점에서 과거 연결주의 모델링 연구와 유사성을 보인다. 하지만 그럼에도 불구하고 두 가지 점에서 결정적인 차이가 있다. 첫째로 학습에 이용된 자극의 구성이다. 서론에서 언급한 바와 같이, 과거 연결주의 모델링 연구들은 속성의 무작위 할당과, 소규모 자극의 사용, 두 가지의 제한점이 있었다. 본 연구에서는 이에 대해 CoreNet에서 제시하는 실제 속성이 적용된 대규모의 자극을 사용하였다. 이는 과거의 연결주의 모델링 연구들에 비해 실제의 개념들 간의 관련성을 더 잘 나타낼 수 있도록 함으로써, 속성적 관점의 검증을 가능하도록 하였다.

둘째로 학습 시에 가중치 변동에 적용되는

학습률을 ARL와 DRL로 나눈 점이다. 이 분리된 학습률은 대규모 자극에 의해 정상적으로 학습이 이루어 질 수 없는 상황을 해소시켰다. 방법 절의 학습 부분에서 언급한 바와 같이, 학습 과정에서 각 속성들은 목표값이 0인 상황이 1인 상황에 비해 극단적으로 높기 때문에 일반적인 단일 학습률로는 정상적인 학습이 이루어질 수 없다. 즉 ALR과 DRL로 분리된 학습률은, 첫 번째 차이점인 대규모 자극이 올바르게 학습될 수 있도록 하였다.

이와 같은 두 차이점은, 이후 의미 처리에 관한 연결주의 모델링 연구에 대규모 자극을 사용 가능하도록 한다는 점에서, 이후의 연구에 고려될 수 있을만한 부분이라 판단된다.

본 연구를 통해 우리는, 속성적 관점이 각 개념의 의미 및 의미 간의 관련성을 표상 가능 한지 알아보았으며, 속성적 관점에서 과거 연구되었던 의미 관련 효과들의 메커니즘을 검증하였다.

본 연구를 기반으로 몇 가지 후속 연구가 진행될 수 있을 것으로 판단한다. 첫째로 속성에 추상 개념이 포함된 연구가 요구된다. 본 연구에서는 출력층의 과도한 증가로 인한 학습시간 증가를 막기 위해 추상 개념이 제외되었으며, 이에 따라 상당한 단어가 제외되었다. 학습을 통한 의미 정보 구성을 명확히 함과 동시에 의미 처리에 있어서 구체어와 추상어 간의 차이를 논하기 위해서는 이와 같은 추상 개념이 포함된 연구가 필요할 것으로 판단된다.

둘째로, 동형이의어(homograph)를 고려한 연구가 요구된다. 단어 중복성 효과(word ambiguity effect)와 같이 어휘 중복이 의미 처리에 영향

을 끼친다는 보고는 많은 행동 실험에서 제시되어 왔으며, 많은 선행 연구들은 실험 내에서 동형이의어에 의한 영향을 통제하고자 하였다(나운혜, 2014; Plaut, 1997; Yim et al., 2005; Ziegler, Perry, & Coltheart, 2000). 따라서 동형이의어에 대한 고려가 서로 간의 단어 관계성을 논하는데 있어서 필요할 것으로 판단된다.

참고문헌

- 김선경, 이혜원 (2007). 한글단어재인에서 청년과 노인의 의미점화효과. 한국심리학회지: 인지 및 생물, 19(4), 279-297.
- 김지혜 (2010). 한국어 시각 단어 재인에서 음운, 표기, 의미 이웃 크기 효과와 과제에 따른 양상. 미발표 고려대학교 대학원 석사학위 청구논문.
- 나운혜 (2014). Behavioral and ERP Correlates of Korean Homographs in Visual Word Recognition by Department of Psychology. 미발표 고려대학교 대학원 석사학위 청구논문.
- 남기춘, 서광준, 최기선, 이경인, 김태훈, 이만영 (1997). 한글 단어 재인에서의 단어 길이 효과. 한국심리학회지: 인지 및 생물, 9(2), 1-18.
- 박권생 (1997). 단어의 의미 파악에 관여하는 음운 정보의 역할. 한국심리학회지: 인지 및 생물, 9(2), 131-152.
- 박태진 (2003). 자료: 한국어 단어의 주관적 빈도 추정치 및 단어 재인에 미치는 빈도 효과. 한국심리학회지: 인지 및 생물, 15(2), 349-366.
- 송진영, 남기춘, 구민모 (2012). 단어 빈도와 음절 이웃 크기가 한국어 명사의 음성 분절에 미치는 영향. 말소리와 음성과학, 4(2), 3-20.
- 이광오, 박현수 (2009). 언어심리학. 서울: 박학사.
- 이창환, 김연희, 강봉경 (2003). 한글 단어 재인에 있어서 음운정보와 시각정보의 역할. 한국심리학회지: 인지 및 생물, 15(1), 1-17.
- 임형욱 (2004). 신경망 모형에 의한 어휘판단과제의 어휘빈도효과와 철자조합적합성효과 모사 연구. 미발표 고려대학교 대학원 석사학위 청구논문.
- 한국과학기술원 전문용어언어공학연구센터 (2005). 다국어 어휘의미망제1권: 어휘의미망구축론. KAIST Press.
- Bock, K., & Levelt, W. (2002). Language production. In *Psycholinguistics: Critical concepts in psychology* (Vol. 5, pp.945-984). Taylor & Francis.
- Collins, A. M., & Loftus, E. F. (1975). A spreading-activation theory of semantic processing. *Psychological Review*, 82(6), 407-428.
- Collins, A. M., & Quillian, M. R. (1972). How to make a language user.
- Cree, G. S., McNorgan, C., & McRae, K. (2006). Distinctive features hold a privileged status in the computation of word meaning: Implications for theories of semantic memory. *Journal of Experimental Psychology. Learning, Memory, and Cognition*, 32(4), 643-658.
- Cree, G. S., McRae, K., & McNorgan, C. (1999).

- An attractor model of lexical conceptual processing: simulating semantic priming. *Cognitive Science*, 23(3), 371-414.
- Dell, G. S. (1986). A spreading-activation theory of retrieval in sentence production. *Psychological Review*, 93(3), 283-321.
- Frank, S. L., Haselager, W. F. G., & Van Rooij, I. (2009). Connectionist semantic systematicity. *Cognition*, 110(3), 358-379.
- Fujihara, N., Nageishi, Y., Koyama, S., & Nakajima, Y. (1998). Electrophysiological evidence for the typicality effect of human cognitive categorization. *International Journal of Psychophysiology*, 29(1), 65-75.
- Harm, M. W. (2002). Parallel Distributed Processing and Cognitive Neuroscience Center for the Neural Basis of Cognition. *Design*, (January).
- Hinton, G. E., & Shallice, T. (1991). Lesioning an attractor network: investigations of acquired dyslexia. *Psychological Review*, 98(1), 74-95.
- Hudson, P., & Bergman, M. (1985). Lexical knowledge in word recognition: Word length and word frequency in naming and lexical decision tasks. *Journal of Memory and Language*, 24, 46-58.
- Hutzler, F., Ziegler, J. C., Perry, C., Wimmer, H., & Zorzi, M. (2004). Do current connectionist learning models account for reading development in different languages? *Cognition*, 91(3), 273-96.
- Johnson-Laird, P. N., Herrmann, D. J., & Chaffin, R. (1984). Only connections: A critique of semantic networks. *Psychological Bulletin*, 96(2), 292-315.
- Jacobs, R. A., & Jordan, M. (1991). A modular connectionist architecture for learning piecewise control strategies. In *American Control Conference 1991* (pp.1597-1602).
- Kwon, Y., & Lee, Y. (2014). Time course of Word Frequency and Word Length Effect in Visual Word Recognition: Evidence from Event-Related Brain Potential Study. *The Journal of Linguistic Science*, 69, 43-62.
- Kwon, Y., Park, K., Lim, H., Jung, S., & Nam, K. (2006). Word frequency effect and word similarity effect in korean lexical decision task and their computational model. *Neural Information Processing*, 4234, 331-340.
- Lei, Y., Li, F., Long, C., Li, P., Chen, Q., Ni, Y., & Li, H. (2010). How does typicality of category members affect the deductive reasoning? An ERP study. *Experimental Brain Research*, 204(1), 47-56.
- McRae, K., Cree, G. S., Seidenberg, M. S., & McNorgan, C. (2005). Semantic feature production norms for a large set of living and nonliving things. *Behavior Research Methods*, 37(4), 547-559.
- Morris, R. G. M. (2004). Long-term potentiation and memory. In T. V. P. Bliss, G. L. Collingridge, & R. G. M. Morris (Eds.), *Long-term potentiation: enhancing neuroscience for 30 years* (1st ed., pp.53-61). Oxford University Press.
- Park, K., Jung, S., Lee, Y., Lee, C.-H., & Lim,

- H. (2011). A computational model for simulating korean visual word recognition. *Information -An International Interdisciplinary Journal*, 14(8), 2669-2684.
- Park, K., & Lim, H. (2014). A computational model explaining language phenomena on Korean visual word recognition. *Cognitive Systems Research*.
- Pexman, P. M. (2012). Meaning-based influences on visual word recognition. In J. S. Adelman (Ed.), *Visual Word Recognition: Volume 2* (1st ed., pp.24-43). Psychology Press.
- Pexman, P. M., Hargreaves, I. S., Siakaluk, P. D., Bodner, G. E., & Pope, J. (2008). There are many ways to be rich: effects of three measures of semantic richness on visual word recognition. *Psychonomic Bulletin & Review*, 15(1), 161-167.
- Plaut, D. C. (1996). Relearning after damage in connectionist networks: toward a theory of rehabilitation. *Brain and Language*, 52(1), 25-82.
- Plaut, D. C., McClelland, J. L., Seidenberg, M. S., & Patterson, K. (1996). Understanding normal and impaired word reading: computational principles in quasi-regular domains. *Psychological Review*, 103(1), 56-115.
- Plaut, D. C. (1997). Structure and Function in the Lexical System: Insights from Distributed Models of Word Reading and Lexical Decision. *Language and Cognitive Processes*, 12(5-6), 765-806.
- Plaut, D. C. (1999). A Connectionist Approach to Word Reading and Acquired Dyslexia: Extension to Sequential Processing. *Cognitive Science*, 23(4), 543-568.
- Plaut, D. C., & Shallice, T. (1993). Deep dyslexia: A case study of connectionist neuropsychology. *Cognitive Neuropsychology*, 10(5), 377-500.
- Reed, S. K. (2000). *Cognition: Theory and Applications* (5th ed.). Wadsworth Publishing.
- Rips, L. J., Shoben, E. J., & Smith, E. E. (1973). Semantic distance and the verification of semantic relations. *Journal of Verbal Learning and Verbal Behavior*, 12(1), 1-20.
- Seidenberg, M. S. (2005). Connectionist Models of Word Reading. *Current Directions in Psychological Science*, 14(5), 238-242.
- Seidenberg, M. S., & McClelland, J. L. (1989). A distributed, developmental model of word recognition and naming. *Psychological Review*, 96(4), 523-68.
- Siegelbaum, S. a, & Kandel, E. R. (2013). Prefrontal Cortex, Hippocampus, and the Biology of Explicit Memory Storage. In E. R. Kandel, J. H. Schwartz, T. M. Jessell, S. A. Siegelbaum, & A. J. Hudspeth (Eds.), *Principles of Neural Science* (5th ed., pp.1486-1521). McGraw-Hill Education.
- Thomas, M. J., & Malenka, R. C. (2004). Synaptic plasticity in the mesolimbic dopamine system. In T. V. P. Bliss, G. L. Collingridge, & R. G. M. Morris (Eds.), *Long-term Potentiation: Enhancing Neuroscience for 30 Years* (1st ed., pp. 349-356). Oxford University Press.
- Vigliocco, G., & Vinson, D. P. (2007). Semantic

- Representation. In *The Oxford handbook of psycholinguistics* (pp.195-215).
- Yap, M. J., Tan, S. E., Pexman, P. M., & Hargreaves, I. S. (2011). Is more always better? Effects of semantic richness on lexical decision, speeded pronunciation, and semantic classification. *Psychonomic Bulletin & Review*, 18(4), 742-750.
- Yermolayeva, Y., & Rakison, D. H. (2014). Connectionist modeling of developmental changes in infancy: Approaches, challenges, and contributions. *Psychological bulletin*, 140(1), 224.
- Yim, H., Lim, H., Park, K., & Nam, K. (2005). A Computation Model of Korean Lexical. In *Advances in Natural Computation* (pp.844-849).
- Ziegler, J. C., Perry, C., & Coltheart, M. (2000). The DRC model of visual word recognition and reading aloud: An extension to German. *European Journal of Cognitive Psychology*, 12(3), 413-430.
- 1 차원고접수 : 2015. 08. 24
수정원고접수 : 2015. 10. 02
최종게재결정 : 2015. 10. 02

Semantic Process Possibility Research in Featural View: Connectionist Modeling

Heejo You¹⁾

Kichun Nam¹⁾

Hosung Nam²⁾

¹⁾Department of Psychology, Korea University

²⁾Department of English language and literature, Korea University

Semantic processing should effectively encode the meaning of a word and represent semantic relationship among individual words. This study proposed a connectionist model employing features as basic units for semantic processing among words and learning the relationship between the words and the associated meanings. The model statistically proved the capability to effectively simulate behavioral results from lexical decision tasks. In addition, the model successfully simulated the frequency effect, the word similarity effect, the semantic richness effect, and the semantic priming effect, which have been observed in behavioral studies. These results suggest that features are possibly basic units for human 's semantic processing.

Key words : conceptual representation, semantic process, featural view, connectionist modeling