

코로나믹스: 복잡계 네트워크의 자기조직화 현상

강 인 제* · 이 덕 희**

논문초록 자연재해, 경제현상 등 다양한 분야에서 편중된 분포의 양상이 목격되며, 수도권에 편중된 코로나 확진자 발생 패턴 또한 이와 무관치 않아 보인다. 하지만 정규분포를 가정하는 전통적인 경제학 접근은 이를 설명하는 데 한계를 가진다. 본 연구는 코로나 확진자 발생 패턴을 복잡계 네트워크의 관점에서 조명하고 동시에 사회적 거리두기 정책효과의 불확실성을 규명하고자 하였다. 분석결과, 코로나 확진자수 분포는 인구분포보다 두꺼운 꼬리를 가진 스케일프리 네트워크 기반의 멱함수 분포를 보이며, 인구분포 이상의 휘발성이 존재함을 발견하였다. 또한 수도권 같은 인구밀집 지역에서는 대규모 네트워크의 자기조직화 메커니즘으로 인해 코로나 확산을 통제하기 위한 거리두기 정책효과의 제약이 있음을 확인하였다. 이상의 결과는 현대경제 사회시스템을 이해하기 위해 복잡계 네트워크 관점에서의 접근이 필요함을 시사한다.

핵심 주제어: 멱함수법칙, 자기조직화, 복잡계 네트워크, 코로나 확진자 분포, 인구분포, 스케일프리 네트워크

경제학문헌목록 주제분류: C8, C4, J1, D8

투고 일자: 2021. 12. 28. 심사 및 수정 일자: 2022. 2. 18. 게재 확정 일자: 2022. 5. 18.


* 제1저자, 한국과학기술원 기술경영학부 박사과정생, e-mail: ijkang@kaist.ac.kr

** 교신저자, 한국과학기술원 기술경영학부 교수, e-mail: dhlhexys@kaist.ac.kr

I. 서론

코로나19가 2년 이상 지속되면서 전염병 확산에 대한 관심이 고조되고 있다. 전염병 확산은 우선 병원균(바이러스)의 특성, 즉 전파력의 강약, 치명률, 전파매체, 감염 기간, 잠복기간 등에 영향을 받는다. 뿐만 아니라 전염병 확산은 병원균을 옮기는 개체의 네트워크 구조, 즉 인구분포, 인구밀도, 이동 패턴 등에도 크게 영향을 받는다.


〈그림 1〉 광역별 일별 신규 확진자 발생 추이



자료: 공공데이터포털.

우리나라의 확진자수 추이에서 유달리 수도권에서 많이 발생하고 있다. 인구 비례로 보면 수도권에서 50% 정도 발생해야 하는데, 항상 70% 내외를 차지하고 있다. 2020년 기준 우리나라 수도권에 거주하고 있는 인구는 약 2,673만 명으로, 약 50.4%를 차지하고 있다. 하지만 2021년 12월 16일 기준 수도권의 누적 확진자 비중은 71.8%이며, 그 비중이 시간이 갈수록 증가하고 있다. 2020년 8월 1일- 2021년 12월 16일 사이 일일 평균 신규 확진자수가 수도권은 836.6명, 비수도권은 309.3명으로 각각 73.0%, 27.0%를 차지하고 있다. 다시 말해 코로나19 확진자수는 인구 규모와 비례적이면서도 그 이상의 관계를 가지는 것으로 추측이 된다.

〈그림 2〉 수도권 vs 비수도권 일별 신규 확진자 발생 추이



자료: 공공데이터포털.

코로나 확진이 대부분 사람과 사람의 접촉으로 전파되는 네트워크 현상이므로 단순히 인구수와는 다르게 네트워크 측면을 주목할 필요가 있다. 네트워크는 노드와 링크로 이루어져 있는데, 이 둘의 관계가 단순하지 않다. 노드가 N 개인 네트워크 시스템에서 노드의 수는 N 이지만 상호작용인 링크 수는 $N(N-1)$ 로 경우의 수가 훨씬 많다. 또 여기에 1개의 노드가 추가되면 노드는 1개 늘어나지만, 링크 수는 $2N$ 개가 증가한다. 이처럼 링크는 개체 간 상호작용의 기회를 훨씬 더 증폭시킨다. 즉 개체와 관계 간에 비선형적 상호작용(nonlinear interaction)이 작동하는 것으로 투입과 산출이 비례적이지 않고 지수적 관계를 가진다는 얘기이다(Helbing, 2012).

이런 구조하에서는 특정 여건에 따라 확진자가 폭발적으로 증가하는 휘발성을 지니고 있다. 단순히 양적 관계뿐만 아니라 대중의 행동을 따라하거나(herding) 정보폭포(information cascade) 같은 질적 성향들이 더해져 시스템의 복잡성이 더욱 증대된다. 소위 복잡계 시스템에서는 개체들의 상호작용이 전체 시스템에 영향을 주어 일종의 유행을 만들어내고, 유행은 다시 개체들의 행동에 영향을 주는 소위 자기조직화 복잡계 시스템(self-organizing complex systems)의 성격을 지닌다(Nicolis and Prigogine, 1989; Helbing, 2012). 이러한 과정에서 시스템은 서서히 진화되지 않고 때로는 임계점이나 특정 정책 변화를 전후로 갑자기 변화하는 모습을 보인다. 사건이 평균으로 수렴하는 것이 아니라 극단으로 발산하는 경향을 지니기 때문에 정규분포보다는 꼬리가 두꺼운 멱함수 분포가 더 흔하게 나타난다(Watts and Strogatz, 1998;

Barabási and Albert, 1999; Karonski and Rucinski, 1997; Kumar et al., 2004). 이와 같이 빈도는 낮지만 매우 큰 규모의 사건이 나타나는 등 정규분포에서는 볼 수 없는 극단적인 사건들이 창발 된다. 코로나 발생 초기 이탈리아나 얼마 전 인도에서 확진자가 폭발적으로 증가하는 현상은 이러한 성질과 관련이 있다고 하겠다.

네트워크 사이언스 측면에서 보면 노드에 연결되는 링크의 확률이 모두 동일한 ‘랜덤 네트워크’(Erdős and Rényi, 1959)가 아닌 특정 노드에 링크가 연결될 확률이 유난히 높은 선호적 부착(preferential attachment)이 존재함으로써 링크를 매우 많이 가진 소수의 노드와 링크가 적은 다수의 노드가 분포하는 ‘스케일프리(scale-free) 네트워크’(Barabási and Albert, 1999)와 관련이 있다. 도시별 인구 규모와 빈도(Clauser et al., 2009)를 비롯하여, 지진, 화재, 정전, 토네이도 등과 같은 재난의 피해 규모와 빈도(Clauser et al., 2009; Jo and Ko, 2014; Becerra et al., 2006), 전기료 변동, 금융위기와 같은 경제 현상에 있어서 가격 및 주가 변동(Weron, 2009; Janczuraand and Weron, 2012)을 대상으로 한 많은 연구들에서 사태의 크기와 빈도 간에 멍함수 분포를 보임으로써 스케일 프리 네트워크가 존재함을 밝히고 있다.

경제이론에서는 이를 전통적인 수확체감원리가 아닌 수확체증원리로 설명하고 있다. 네트워크 세계에서는 재화나 서비스를 많이 사용할수록 한계가치가 감소하는 것이 아니라 반대로 한계가치가 증가하게 된다(Arthur, 1989, 1990, 1996). 그러므로 상호경쟁을 통해 일정한 균형점으로 수렴하는 것이 아니라 한쪽으로 쏠리게 되어 발산하게 된다. 따라서 시장 상황에 따라 균형이 달라져 다수의 균형이 존재함으로써 시장의 불안정성이 높아진다. 소위 시장쏠림이나 양극화 현상이 빈번히 일어난다. 미시경제학에서는 이를 네트워크 외부성(network externalities) 개념으로 설명하고 여러 경제 현상에 응용하고 있다(Tirole, 1988; Katz and Shapiro, 1985)

디지털화와 정보화를 동력으로 구현되고 있는 초연결사회는 바로 이러한 네트워크 분포의 변화를 기반으로 복잡하게 변모하고 있다. 일종의 네트워크 현상인 확진자의 발생 패턴은 이러한 복잡계 네트워크 사회와 닮아있다. 확진자 발생 패턴에 대한 분석은 현대와 같은 복잡계 네트워크 사회를 이해하고 문제를 해결하는데 새로운 접근법을 시사할 것으로 기대된다.

본 연구는 이러한 문제의식으로 우리나라의 지역별 코로나19 확진자 분포에 대한 통계분석을 통해 복잡계 네트워크 현상임을 규명하고 경제 현상을 이해하고 정책적 대안을 마련함에 있어서 새로운 관점을 제시한다. 2장에서 지역별 인구분포와 확진자 분포의 비교 분석을 통해 확진자 분포가 두꺼운 꼬리의 멍함수 분포적 특징을 지니고

있음을 밝힌다. 3장에서는 지역간 사회적 거리두기 정책의 효과를 비교하여 확진자 분포의 복잡계 네트워크적 특성을 논한다. 그리고 마지막으로 경제 현상에 대한 새로운 접근을 시사하면서 결론을 맺는다.

II. 복잡계 네트워크 현상

1. 인구수와 확진자수의 비선형적 상호작용

상기 기술한 바와 같이 수도권, 특히 서울의 코로나 신규확진자는 타 지역 대비 급증하는 추이를 보인다. 단순히 인구수가 많을수록 확진자가 많다고 가정할 수 있지만, 아래 <표 1>, <그림 3>과 같이 지역별 인구수와 확진자 간의 관계를 비교해보았을 때 둘 간의 비례적인 관계로 가정하는 것은 적합하지 않다.

전염병의 확산이 개인 간 접촉에 의해 이루어진다는 점을 고려할 때, 이론적으로는 개인 단위를 노드로 설정한 네트워크 기반의 분석이 필요하다. 하지만, 데이터의 한계 등으로 인해, SIR (Susceptible - Infective - Recovered) 또는 SIS (Susceptible - Infective - Susceptible) 모델에 기반한 시뮬레이션 방법론을 사용하거나(Keeling and Eames, 2005; Pastor-Satorras and Vespignani, 2001), 메타개체군 네트워크 (metapopulation network)에서의 전염병 확산을 규명하는 연구들은 지역 또는 도시 단위를 네트워크의 노드로 이용하였다(Appolloni et al., 2014; Tizzoni et al., 2015). 뿐만 아니라 전염병 확산규모를 도시의 특성으로 전제하고, 전염병 확산 분포를 도시규모와의 관계를 통해 규명하고자 하였다(Schalpfer et al., 2014; Tizzoni et al., 2015; Bettencourt, 2013). 따라서 본 연구도 코로나 확진자수 분포를 설명하기 위해서 개인 간의 링크가 아닌 도시규모의 측면에서 분석하기 위하여 시도별 확진자수를 중심으로 분석하였다.¹⁾

<표 1>은 수도권과 비수도권의 관계를 포함하여 서울을 포함한 7개의 특별시·광역시(이하 광역시)와 인접 도(道) 간의 관계를 인구수 및 누적 확진자수의 차이 측면

1) 이처럼 사회경제적 현상을 복잡계 네트워크 측면에서 먹힘수분포를 따르는지 분석할 때, 분석대상을 노드와 해당 노드의 링크 수의 관계에 국한되어 사용되지 않고 있다. 일례로 단어의 빈도수, 테러공격의 심각성, 자연재해의 피해규모, 책 판매량 등과 같이 네트워크 내 관계로 정의하기 어려운 현상들의 분포가 먹힘수분포를 따르는지 분석하였다(Clauset, Shalizi, and Newman, 2009; Jo and Ko, 2014)

에서 보여주고 있다. 수도권 인구수는 비수도권 인구수의 1.018배 수준으로 거의 차이가 없지만, 확진자수는 2.543배의 차이를 보였으며, 광역시도 단위에서 또한 평균 확진자수의 차이가 평균 인구수의 차이보다 약 1.365배 큰 것으로 나타났다. 경기도의 경우, 인천보다 약 4.586배 더 많은 인구를 보유하고 있지만, 확진자수는 그 이상인 5.244배 차이가 났으며, 부산은 경상남도과 비슷한 인구규모(1.009배 차이)를 가지고 있지만, 확진자수는 1.141배 차이가 났다. 대전 또한 인접한 세종보다 4.103배 이상의 인구규모를 가졌지만, 확진자수는 그 이상인 5.947배 더 많이 발생한 것으로 나타났다.

서울과 대구, 광주도 인접 도보다 인구수는 적지만, 더 많은 확진자가 발생하였다. 서울은 경기도보다 인구가 0.718배 차이가 나지만, 확진자수는 1.667배 더 많은 것으로 나타났다. 대구와 광주 또한 각각 경북과 전남과의 인구수를 비교하였을 때, 0.909배, 0.781배만큼 적었으나, 확진자수는 1.709배, 1.682배만큼 더 많이 발생하였다. 이는 확진자수는 인구 규모와 더불어 인구밀도 요인도 관계되어 있음을 암시한다.

〈표 1〉 광역시 - 인접 도(道) 간 확진자수 및 인구수 차이


A - B	인구수 차이 (A/B)	확진자수 차이 (A/B)
수도권 - 비수도권	1.018	2.543
서울 - 경기	0.718	1.196
경기 - 인천	4.586	5.244
대전 - 세종	4.103	5.947
대구 - 경북	0.909	1.709
울산 - 경남	0.339	0.353
광주 - 전남	0.781	1.682
부산 - 경남	1.009	1.141

주: 확진자와 인구는 각각 2021년도 12월16일, 8월27일 기준

자료: 공공데이터포털, 국가통계포털.

아래 〈그림 3〉은 인구수와 확진자수를 각각 X축, Y축으로 설정하고, 둘 간의 관계를 도식화한 것이다. 인구수와 확진자수 간의 관계를 단순히 투입과 산출의 측면에서 보았을 때, 시도별 확진자수는 인구수에 비례하여 상승하지 않으며, 오히려 지수적 관계를 형성하고 있다.

〈그림 3〉 인구-확진자 관계



자료: 공공데이터포털.

코로나 확진자수가 인구가 밀집된 지역을 중심으로 증폭되는 현상은 확진자수가 절대 인구 규모와 인구밀도가 복합적으로 작용하는 복잡계 네트워크 현상임을 의심하게 한다. 전술한 바와 같이, 코로나의 확산은 비확진자(susceptible individuals)와 확진자(infectious individuals) 간의 접촉에 의해 코로나바이러스가 전파되는 네트워크의 특징을 가지고 있다. 노드와 링크로 구성된 기존 네트워크에서 새로운 노드가 추가될 때 이미 상호작용이 잘 이루어지고 있는 부분에 새로운 노드가 연결되는 경향을 보이며, 이로 인해 대규모의 네트워크 내에서는 자기조직화 현상이 두드러진다(Barabási and Albert, 1999).

2. 확진자수 분포의 멱함수법칙

본 절에서는 확진자수 분포의 네트워크적 특징을 실증적으로 규명하기 위하여 동분포가 ‘두꺼운 꼬리를 가진 멱함수 분포’를 따른다는 가설을 검증하고자 한다. 이에 따라, 다음과 같이 두 개의 가설을 중심으로 확진자수 분포의 특징을 밝힌다.

가설1, 확진자수 분포는 멱함수분포를 따른다.

가설2, 확진자수 분포는 인구수 분포보다 두꺼운 꼬리를 가진다.

확진자수 분포가 멱함수 분포를 따른다는 것은 확진자의 증가폭은 네트워크 기반의 확장, 즉 자기조직화 복잡계 시스템에 의해 결정된다는 것을 의미한다(Jacson and

Rogers, 2007). 그리고 확진자수 분포가 인구수 분포보다 두꺼운 꼬리를 가진다는 것은 확진자수의 증폭이 네트워크효과에 의해 소수 지역을 중심으로 극단적인 사례로 발전될 수 있음을 뜻한다.

가설검증을 위해 공공데이터 포털에서 open API 형태로 제공하는 “코로나19 시도 발생 현황” 데이터를 이용하였다.²⁾

(1) 스케일프리 네트워크

멱함수 분포만이 스케일프리 네트워크의 특징을 가지고 있다(Farber, 2003; Newman, 2005; Broido and Clauseet, 201). 스케일프리 또는 스케일 불변성(scale-invariance)은 Barabási and Albert(1999)가 처음 제시한 개념으로, 자기조직화 기반의 네트워크 확장에 따른 멱함수 분포를 설명하기 위해 사용되었다. 이때 스케일프리란 멱함수 $p(x) = ax^k$ 라고 할 때, x 의 단위가 바뀌더라도 k 가 변하지 않고 $p(x)$ 분포의 모양이 유지되기 때문에 붙여진 이름이다. 즉, 멱함수 분포는 x 가 bx 만 큼 증가할 때, $p(bx) = a(bx)^k = b^k p(x) \propto p(x)$ 와 같이 지수 k 가 척도의 영향을 받지 않는다(Yip, Shadbolt, and Webber, 2012; Broido and Clauseet, 2019; Zhou, Meng, and Stanley, 2020).

스케일프리 네트워크는 선호적 부착 메커니즘에 의해 네트워크가 확장된다(Barabási and Albert, 1999; Keller, 2005; Pachon, Sacerdote, and Yang, 2018; Broido and Clauset, 2019). 만일 네트워크가 랜덤 연결(random link)로 확장된다면 기존 네트워크 내 노드들이 동일한 확률로 새로운 노드와 연결되어 유난히 연결이 많은 노드들이 발생하기 어렵다. 하지만 스케일프리 네트워크에서는 기존 노드들이 네트워크 내에서 점하는 위치에 의해 새로운 노드와 연결될 확률이 결정된다. 기존 네트워크 내 링크가 많은 노드일수록 새로운 노드와 연결될 확률이 높아지는 소위 ‘선호적 부착’ 메커니즘이 작동된다(Jacson and Rogers, 2007). 이로 인해 시간이 지날수록 점점 다수의 링크를 가진 소수의 노드와 소수의 링크를 가진 다수의 노드로 구성되는 경향을 보인다(Barabási and Bonabeau, 2003).

코로나 확산이 확진자(기존 노드)와 비확진자(새로운 노드) 간의 직접적인 접촉에 의해 이루어진다고 가정한다면, 많은 링크를 가진 확진자일수록 비확진자와 접촉할

2) <https://www.data.go.kr/data/15043378/openapi.do>.

확률이 높다고 추론할 수 있다. 수도권처럼 인구가 밀집된 지역은 그만큼 타 지역들보다 확진자와 비확진자가 접촉할 확률이 높기 때문에 확진자수는 멱함수 분포를 따를 것이라는 첫 번째 가설을 설정하였다.

랜덤 네트워크는 종형 분포(bell-shaped distribution)를 보이지만, 스케일프리 네트워크는 지속적으로 감소하는 형태의 분포를 띤다(Barabási and Bonabeau, 2003). 〈그림 3〉과 같이 도시 단위에서의 확진자수와 인구규모와의 관계가 스케일 불변의 관계를 갖고 있는 것을 보여줌으로써 확진자수분포가 멱함수분포를 따르는지 추정할 수 있다(Schälpfer et al., 2014; Bettencourt, 2013; Tizzoni et al., 2015).³⁾ 하지만 시각적으로 심한 왜도(highly skewed) 형태의 분포를 보이더라도 멱함수 법칙에 부합하지 않는 경우가 존재하기 때문에 모델적합도 분석 절차가 필요하다(Newman, 2005).

모델적합도를 분석하기 위해서는 크게 두 가지 방법이 이용된다. 하나는 부트스트랩(bootstrapping)을 이용하여 특정 분포에 대한 개별적인 평가를 실시하는 것이다. 동 방법은 해당 분포가 멱함수 분포를 따르는지 보여줄 수 있지만 멱함수 분포가 가장 적합한지를 설명하는 데는 한계가 있다. 이를 보완하기 위한 또 다른 방법으로 다양한 후보들 중 어떤 분포가 가장 적합한지를 비교하는 방법이 널리 사용되고 있다(Alstott, Bullmore, and Plenz, 2014).


후보 분포 간 비교를 통해 멱함수 분포가 가장 적합한지 분석하기 위하여 2021년 12월 16일 기준 시도별 누적 확진자수에 대한 데이터를 이용하여 멱함수 분포와 기타 후보 분포 간의 loglikelihood ratio를 계산하였다. 결과값이 양수이면 멱함수 분포가 대조군보다 더 적합한 것을 의미한다. 이를 위해 관련 선행연구를 참조하여 지수분포(exponential distribution)와 로그정규분포(log-normal distribution)⁴⁾를 대조군으로 선택하였다. 지수분포와 로그정규분포는 모두 심한 왜도 형태의 분포를 보이며, 로그-로그 분포상으로도 멱함수 분포와 유사한 형태로 나타나지만 스케일프리의 성격을 가지지 못하고 있다는 점에서 멱함수 분포와 비교하기 위한 대조군으로 자주 사용된다(Newman, 2005, 2017; Duxbury and Haynie, 2018; Broido and Clauset, 2019). 특히 지수분포는 상대적으로 얇은 꼬리와 낮은 분산을 보이는 반면, 로그정규

3) 그들은 도시 단위에서 확진자수(Y)와 도시규모(N)의 관계가 “초선형적 스케일 불변(superlinear scale-free)”의 관계를 갖는지 분석하였다($Y \propto N^\beta$)

4) 로그정규분포는 확률변수(random variable)을 로그값으로 치환했을 때 정규분포를 따르는 경우를 의미한다.

분포는 두꺼운 꼬리를 가지고 있어 멱함수 분포와 유사성이 더 높으나 스케일프리의 성격은 가지고 있지 않다(Broido and Clauset, 2019). 다시 말해 두 분포는 시각적으로 멱함수분포와 유사성을 띠고 있지만, 네트워크가 확장되는 과정에서 새로운 노드가 선호적 부착에 의해 기존 네트워크와 연결되지 않음을 시사한다(Dorogovstev and Mendes, 2002).

〈그림 4〉 확진자분포를 설명하기 위한 멱함수분포, 로그정규분포, 지수분포



주: 좌측 그림 (A) 은 시도별 확진자분포에 대한 멱함수, 지수, 로그정규분포의 시각화 결과이며, 우측 그림 (B) 은 위 결과의 특정 부분을 확대한 결과.

위 〈그림 4〉는 17개 광역시도별 확진자 데이터에 대해 상보누적함수(CCDF, complementary cumulative distribution function)⁵⁾로 표현했을 때, 멱함수분포와 지수분포, 그리고 로그정규분포 등 세 개의 분포가 얼마나 적합한지 도식화한 결과이다. 이때, 파란색 실선은 실제 데이터를 CCDF 형태로 나타냈을 때의 결과이며, 그 외 선들은 해당 데이터를 설명하기 위해 사용된 상기 세 개 분포도 결과이다. 붉은색 실선, 녹색 점선, 그리고 파란색 점선은 각각 멱함수분포, 로그정규분포, 지수분포를 나타낸다. 멱함수분포와 로그정규분포 간 유사한 형태를 보이지만 지수분포와는 큰 차이가 있는 것으로 나타났다.

하지만 이와 같은 ‘질적 접근법’은 시각적인 한계, 꼬리 부분의 노이즈 제거 등으로

5) Newman (2005)을 참조하여, 광역시도별 확진자수를 내림차순으로 정리하여, 해당 순서에 맞춰 순위를 매기는 방식의 CCDF로 표현하였다. 이때, CCDF는 $P(X \geq x)$ 와 같이 표현이 가능하다(Clauset, Shalizi, and Newman, 2009; Alstott, Bullmore, and Plenz, 2014). $X \geq x$ 에 대한 예시를 들면, 가장 많은 확진자를 가진 서울의 확진자수를 x_1 라고 했을 때, x_1 이상의 확진자수가 발생한 지역은 서울 하나일 것이다. 그 다음으로 많은 확진자를 가진 경기도의 확진자수를 x_2 라고 했을 때, x_2 이상의 확진자수가 발생한 지역은 서울과 경기도 두 곳이 된다.

인해 멱함수분포의 적합도를 평가하는데 다소 한계를 지닌다. 이를 보완하기 위해 Clauset, Shalizi, and Newman (2009) 은 log-likelihood ratio를 이용한 두 분포 간의 비교분석방법을 제시하였다. Log-likelihood ratio를 이용한 분포 간 비교분석 결과, 확진자분포는 지수분포보다 멱함수분포로 설명하는 것이 유의한 차이로 더 적합한 것으로 나타났다.

〈표 2〉 확진자분포 관련 멱함수분포와 대조군 비교

대조군	$P(x) \propto f(x)$	Loglikelihood Ratio (p-value)
지수분포	$\lambda e^{-\lambda x}$	2.856 (0.004) ***
로그정규분포	$\frac{1}{\sqrt{2\pi}\sigma} \frac{1}{x} \exp[-\frac{1}{2}(\frac{\ln(x)-\mu}{\sigma})^2]$	0.684 (0.494)

주: 시도별 확진자수에 대한 멱함수분포는 $P(K > k) \sim Ck^{-\gamma}$ 로 정의되며, 이때, k 는 시도별 확진자 수, C 는 상수를 의미.

통계적 유의성: $p < 0.01$ (***) , $p < 0.05$ (**), $p < 0.1$ (*).

반면 로그정규분포와는 유의한 차이를 보이지 않았다. 멱함수분포와 유사하게 로그정규분포 또한 심한 왜도와 두꺼운 꼬리 형태의 분포도를 가지고 있기 때문에 둘 간의 유의한 차이가 나타나지 않을 가능성이 존재하기 때문이다(Duxbury and Haynie, 2018)⁶⁾. 또한 복잡계 네트워크가 다양한 네트워크의 특징을 가지고 있기 때문에(Freitas et al., 2019), 코로나 확산이 전적으로 선호적 부착 혹은 무작위로 이루어지지 않고 이 둘의 공존에 의해 이루어지는 것이 더 일반적일 것이다(Yip, Shadbolt, and Webber, 2012). 그런 면에서 로그정규분포와 멱함수분포 모두의 성격을 가질 수 있다(Danon et al., 2012)⁷⁾. 그러나 수도권외의 과밀 인구는 일정 임계점 이후에는 타지역보다 훨씬 더 개인 간 접촉 확률을 높이기 때문에 선호적 부착의 힘이 더 강하게 작용할 수 있다.

그럼에도 불구하고 멱함수분포와 후보분포 간 적합도 비교분석을 통해서도 확진자

6) 데이터에 가장 적합한 분포유형을 선택하는 방법에 대한 명확한 해결방안은 아직까지 제시되지 못하고 있다. 특히, 두꺼운 꼬리를 갖는 로그정규분포의 경우 다수의 분포에서 멱함수분포와 유사한 수준의 적합도를 보인다(Broido and Clauset, 2019).

7) 이와 관련해서 Danon et al. (2012) 은 n 개의 링크를 가진 개인의 접촉률이 $f(n) = n + \alpha$ 에 비례한다고 가정하였을 때, $\alpha = 0$ 이라면 선호적 부착에 의해서만 접촉률이 결정되지만, α 가 충분히 크다면 α 에 의해 무작위 네트워크가 형성되기 때문에 로그정규분포와 멱함수분포 모두의 특징을 보인다고 주장하였다.

수분포가 멱함수분포를 따른다는 첫 번째 가설을 채택할 근거가 다소 부족하다. 따라서 본 연구는 멱함수분포가 확진자수 분포를 설명하기 적합한 분포인지 분석하기 위하여 Clauset, Shalizi, and Newman(2009)이 제시한 다음과 같은 과정을 통해 Kolmogorov-Smirnov(KS) 검증을 실시하였다. 첫째, 실제 데이터를 이용하여 멱함수분포를 추정하고, 해당 멱함수분포의 지수값과 최소값을 이용하여 다수의 가상데이터를 구축한다. 둘째, 실제 데이터와 각각의 가상데이터에 대한 KS검증을 통해, 유의수준 0.1을 기준으로 귀무가설을 기각할 수 없는지 분석한다. 이때 귀무가설은 두 데이터가 동일한 분포의 형태를 띠는 것을 의미하기 때문에, KS검증 결과 p-value가 0.1보다 크다면 실제 데이터가 멱함수분포를 따른다는 가설을 채택할 수 있다.

상기 과정을 통해 1,000개의 가상데이터를 구축하고, 각각의 가상 데이터와 실제 데이터를 이용하여 KS 검증을 실시한 결과, 984개의 사례에서 p-value값이 0.1보다 큰 것으로 나타났다. 따라서 본 연구는 확진자수분포는 멱함수분포를 따른다는 첫 번째 가설을 채택하였다.

(2) 두꺼운 꼬리분포

멱함수법칙을 따르는 분포의 또 다른 특징은 지수분포, 포아송분포, 정규분포 등 다른 분포보다 두꺼운 꼬리를 가지고 있다는 것이다. 꼬리의 두께는 분포의 감소율을 의미하며, 꼬리가 두꺼울수록 최상위값의 비율이 크고 천천히 감소하는 형태를 띤다(Hein, Schwind, and König, 2006; Benhabib and Bisin, 2017). 따라서 확진자수의 분포가 두꺼운 꼬리의 멱함수분포를 따른다는 것은 특정 소수 지역을 중심으로 상대적으로 많은 확진자수가 발생할 확률이 정규분포 등 다른 분포보다 상대적으로 높다는 것을 의미한다. 즉, 소수 지역을 중심으로 확진자가 증폭할 확률이 지역별 인구 비율보다 높다고 할 수 있다. 꼬리의 두께를 결정하는 멱함수분포의 지수 α 는 일반적으로 $2 \leq \alpha < 3$ 범위 내의 값을 갖는다. 이때 α 가 해당 범위 내의 값을 갖는다는 것은 유한한 평균값을 가지지만 분산은 무한대로 증가하는 것을 의미한다(Clauset, Shalizi, and Newman, 2009; Newman, 2017).

두 번째 가설을 검증하기 위하여 본 연구는 인구수와 확진자수 분포의 지수를 비교하였다. 두 분포의 지수를 측정, 비교하기에 앞서 전술한 방법과 동일하게 인구수도 멱함수분포를 따르는지 분석하였다. 분석 결과, 지수분포보다는 유의한 차이로 더 적합한 것으로 나타났지만 로그정규분포와는 유의한 차이를 보이지 않았다. 마찬가지로

로 KS검증 결과, 985개의 사례에서 p-value가 0.1보다 크게 나왔기 때문에 먹힘수분포를 따른다는 가설을 지지할 수 있는 것으로 나타났다.⁸⁾

〈표 3〉 인구수분포 관련 먹힘수분포와 대조군 비교


대조군	Loglikelihood Ratio (p-value)
지수분포	1.868 (0.062) *
로그정규분포	0.239 (0.811)

주: 시도별 인구규모에 대한 먹힘수분포는 $P(N > n) \sim Cn^{-\eta}$ 로 정의되며, 이때, n 은 시도별 인구수, C 는 상수를 의미

통계적 유의성: $p < 0.01$ (***), $p < 0.05$ (**), $p < 0.1$ (*).

위 결과들을 토대로 본 연구는 인구수와 확진자수 분포 모두 먹힘수분포를 따른다는 가정하에, 두 분포 꼬리의 두꺼운 정도를 비교하였다. 인구수 및 확진자수 분포가 각각 $P(N > n) \sim Cn^{-\eta}$, $P(K > k) \sim Ck^{-\gamma}$ 를 따른다고 하였을 때, η 값이 γ 값보다 크다면, 확진자수 분포가 더 두꺼운 꼬리분포를 가진다(Jo and Ko, 2014; Benhabib and Bisin, 2017).

〈그림 5〉 인구수 및 확진자수에 대한 이중로그척도 결과



먹힘수분포의 지수를 측정하기 위해서 많은 관련 선행연구들이 이중로그척도

8) 확진자수 분포처럼, 먹힘수 분포를 따른다는 가설을 지지하지만, 로그정규분포의 가능성을 배제할 수는 없다.

(double logarithmic scale)를 이용하여 직선상의 기울기값을 이용한다. <그림 5>는 인구수 및 누적확진자에 대한 이중로그척도의 결과이며, 확진자데이터와 인구데이터에 대한 기울기는 각각 -0.643, -0.868로 나타나며,⁹⁾ 확진자 분포가 더 두꺼운 꼬리 분포를 가진다는 가설을 채택할 수 있다.

한편 이중로그척도를 이용한 멱함수분포의 꼬리 두께 추정은 편의추정량의 문제가 발생할 우려가 있으므로 분산 및 최대우도법(maximum likelihood method, MLE)을 분석하여 보완하였다(Newman, 2005; Clauset, Shalizi, and Newman, 2009; Newman, 2017). 확진자수와 인구수를 로그값으로 치환 후 분산을 계산한 결과 각각 0.246, 0.135를 기록하여 확진자의 분산이 더 큰 것으로 나타났다. MLE 또한 확진자수의 분포가 더 작은 것으로 나타나 확진자수가 인구수보다 더 두꺼운 꼬리분포를 가지는 것을 재차 확인할 수 있다.

확진자수가 인구수보다 더 두꺼운 꼬리의 멱함수분포를 보이는 것은 확진자수 분포 내 최상위값의 비율이 인구수 분포에 비해 더 많으며, 그 감소폭은 더 적은 것을 의미한다(Benhbib and Bisin, 2017). 특정 값(예로 들어 평균값) 이상의 확진자수를 가진 지역의 비율이 인구수의 경우보다 더 크며, 그 값이 커질수록 해당 조건을 충족시키는 지역의 비율이 더 작은 폭으로 감소한다.

이는 확진자수 분포에서보다 더 극단적인 지역이 존재하며, 수도권과 같이 인구가 밀집된 지역이 그렇지 못한 지역에 비해 인구 비율 대비 높은 확진자수를 발생시킬 수 있음을 말한다. 바로 수도권에 절대 인구가 많아 잠재적 연결 수가 많은데다 또한 인구밀도도 높아 실제 접촉 확률이 높기 때문이다.

<표 4> 인구분포 및 확진자분포의 꼬리 두께

구분	이중로그척도 기울기	MLE	로그분산
확진자	-0.643	2.145	0.261
인구	-0.868	2.609	0.138

9) 후술한 바와 같이, 편의추정량의 가능성이 있기 때문에, 이중로그척도를 이용한 기울기를 통해 멱함수분포의 꼬리를 추정하는 것에 대한 우려가 존재한다. 본 결과에서 멱함수분포의 지수의 일반적인 범위 밖의 결과가 나온 것은 이와 같은 문제로 인한 것으로 추정된다.

Ⅲ. 복잡계 네트워크 현상과 사회적 거리두기 정책의 효과

1. 복잡계 네트워크에 따른 정책효과의 이질성

앞서 살펴본 대로 코로나19의 확진자 발생이 복잡계 네트워크 현상이고, 이로 인해 인구분포 이상으로 치우쳐진 분포, 즉 멱함수 분포를 보임을 분석하였다. 이런 휘발성이 높은 분포 하에서 기존의 정책적 접근은 한계를 지닐 수밖에 없다. 이를 보완하기 위하여 경제학, 행정학, 정책학 등의 분야에서는 기존 이론들과는 상이한 새로운 관점이나 시도들이 활발히 이루어지고 있다.

전통적인 사회과학에서는 조직구조 및 정책이 적절하다면 정책목표를 달성할 수 있다고 가정하고 있으며, 이에 따라 정부 주도의 하향식 기조의 조직구조와 정책을 개발하는 데 초점을 두었다. 하지만 최근 연구들에서는 정책집행 과정에서 지역 단위의 주체들 간의 상호작용에 따른 동태적 정책집행 과정을 설명하기 위해 복잡계 이론의 개념을 접목하고 있다(Butler and Allen, 2008; Klijn, 2008; Teisman and Klijn, 2008; Eppel, Matheson, and Walton, 2011; Cairney, 2012; Castelnovo and Sorrentino, 2018).

이들은 특정 정책이 시행되었을 때 관련 주체들 간 상호작용 및 피드백루프를 통해 자기조직화가 이루어지며, 이로 인해 정책효과의 불확실성이 증대된다고 주장한다(Cairney, 2012). 즉, 해당 정책이 제시하고 있는 정태적 규칙에 따라 행동하는 것이 아니라 자기조직화에 의해 서로 영향을 미치며 공진화하기 때문에 그 변화의 방향성과 속도를 예측하는 데 한계가 있기 때문이다(Teisman and Klijn, 2008). 특히, 자기조직화 패턴이 다양해질수록 변화를 예측하기 더 어려워진다고(Eppel, Matheson, and Walton, 2011). 밀집된 네트워크일수록 상호작용이 복잡하게 이루어진다는 점을 고려한다면 인구가 밀집된 지역일수록 정책효과의 불확실성이 증대될 것으로 추정할 수 있다.

이처럼 복잡계 네트워크에 따르면 구성원들은 주어진 정책에 따라 행동하는 것이 아니라, 자기조직화에 따라 행동 양상을 결정한다. 따라서 정책효과의 이질성의 요인을 직접적으로 분석하기 위해서는 독립변수로써 네트워크 내 상호작용의 수치화가 선행되어야 하지만, 사회과학계열에서 구성요소(또는 구성원) 간 상호작용을 정량적으로 수식화하는데 한계가 있다(민병원·김창욱, 2006). 또한 복잡계 네트워크에 따르면 구성요소 간의 자기조직화뿐 아니라 정책집행과정에서 다양한 동태적 요인들이 영

향을 미친다고 전제하고 있기 때문에 직접적인 인과관계 분석 대신 동태적 현상을 규명하는데 더 초점을 두고 있다(Teisman and Klijn, 2008). 이에 따라 본 장에서는 코로나 확산에 대응하기 위한 정책이 지역에 따라 정책의 효과가 상이하게 나타나는 것을 규명함으로써 확진자 발생이 복잡계 네트워크의 자기조직화 현상임을 간접적으로 증명한다(Cairney, 2012). 이를 위해 본 연구는 서울과 경기도에서 동일하게 거리두기 정책을 폈음에도 불구하고 두 지역 간 정책효과의 차이가 발생하였는지 분석하였다.

2. 사회적 거리두기 정책의 효과 차이 분석

복잡계 시스템 내에서 자기조직화에 의해 상이한 정책효과가 발생하는지를 실증적으로 분석하기 위하여, 코로나 확산을 완화시키기 위한 정부의 대표적 비약학적 개입(nonpharmaceutical interventions)인 ‘사회적 거리두기’ 정책효과가 인구밀집도에 따라 차이가 있는지 검증한다.

최근 정책효과를 분석하기 위한 비교연구방법론으로 많은 연구자들이 이중차분법(difference-in-differences, DID)을 활용하였다. DID를 통해 의도적인 개입이 이루어진 집단(이하 처치집단)과 그렇지 않은 집단(이하 통제집단) 간 비교분석을 통해 정책효과로 인한 처치집단에서 유의한 차이가 발생하는지 추정할 수 있다. DID를 사용하기 위한 기본가정 중 하나는 두 집단 간의 동일한 추세(공통추세)이지만, 상당수의 사례가 이를 충족시키지 못한다.

이를 보완하기 위하여 Abadie, Diamond, and Hainmueller (2010)는 통제집단의 데이터를 이용하여 가상의 처치집단을 생성하여 실제 처치집단과 비교할 수 있는 합성대조법(synthetic control method, SCM)을 개발하였다. 즉, SCM을 통해 의도적인 개입의 이루어지지 않았을 경우의 처치집단을 추정하고, 이를 실제 처치집단과 비교함으로써 정책효과를 추정할 수 있다. 따라서, 비약학적 개입 관련 정책들의 효과 여부를 탐색하기 위하여, 동 정책이 실시된 시점 전후로 ①해당 정책을 실시한 국가(또는 지역)와 ②해당 정책을 실시하지 않은 가상의 유사한 국가(또는 지역) 간 확진자 추이가 유의한 차이가 나타나는지 분석하였다(Cho, 2020; Born, Dietrich, and Müller, 2020; Friedson et al., 2020).

하지만 SCM 또한 낮은 적합도 수준, 해석하기 어려운 불확실성 추정값 등의 문제를 내포하고 있다(Xu, 2017; Zhang et al., 2019; Zhao and Niango, 2021). 이를

보완하기 위하여 Xu (2017)은 일반화통제집단합성법(generalized synthetic control method, GSCM)을 개발하였다. GSCM은 기존 SCM에 Bai (2009)가 개발한 고정효과 상호작용 모형(interactive fixed effects model)을 접목시킴으로써 관측되지 않은 시간가변요인들을 추정하여 가상의 통제집단을 생성한다. 이처럼 통제집단에 대한 더 많은 정보를 사용하기 때문에, GSCM이 SCM보다 의도적인 개입 이전의 추세를 더 정교하게 추정할 수 있는 모델이다(Xu, 2017; Bischof and Wagner, 2019).

GSCM을 통해 처치집단과 가상의 처치집단 간의 차이를 분석하여, 평균처리효과(average treatment time effect on the treated, ATT)¹⁰를 계산할 수 있으며, 이를 통해 정책효과의 정도를 추정할 수 있다(Zhang et al., 2019; Bischof and Wagner, 2019; Zhao and Niango, 2021). 이때, 각 시기별 ATT와 p-value 값을 계산할 수 있기 때문에, 어느 시점부터 유의한 수준의 차이로 정책효과가 발생하였는지 분석이 가능하다.

따라서 본 연구는 자기조직화 발생 여부를 간접적으로 검증하기 위하여 정책효과의 차이가 존재하는지 분석한다. 이를 위해, GSCM을 이용하여 2020년 12월 8일 실시된 ‘사회적 거리두기 2.5단계’가 서울과 경기도의 일별 누적 코로나 확진자수에 미치는 영향을 비교분석한다(Cho, 2020; Born, Dietrich, and Müller, 2020; Friedson et al., 2020).¹¹⁾ 2020년 12월 6일, 정부는 동월 8일 9시부터 수도권 지역의 사회적

10) GSCM은 관측된 공변량(observed covariates), 관측되지 않은 공통요인(unobserved common factor), 요인적재값(unknown factor loading)을 이용하여 종속변수 Y_{it} 를 추정한다. 이를 기반으로 하여 다음과 같은 공식에 따라 ATT를 계산한다.

$$ATT_{t,t > T_0} = \frac{1}{N_{tr}} \sum_{i \in \Gamma} [Y_{ti}(1) - Y_{ti}(0)]$$

T_0 은 의도적인 개입이 발생한 시기를 의미하며, Γ 는 처치집단의 묶음(sets of units in treated groups)을 나타낸다. $Y_{ti}(1)$ 는 처치집단 내 i 가 t 시기에 관측된 결과값인 반면, $Y_{ti}(0)$ 은 동일시기 가상의 유닛 i 의 추정 결과값을 의미한다(Xu, 2017). 따라서 ATT는 처치집단에서 관측된 결과값과 가상의 처치집단에서 추정된 결과값의 차이의 평균을 계산한 결과이다.

11) 앞서 기술한 바와 같이, 복잡계 네트워크의 관점에 따르면 자기조직화에 의해 동일한 정책이라도 시기·지역에 따라 정책효과가 상이하다. 따라서 서울과 경기도 중심의 전국적 대유행 확산을 저지하기 위해 두 지역에서 동일하게 실시한 사회적 거리두기 2.5단계의 효과의 차이가 존재한다면, 이는 해당 거리두기 정책에 대한 두 지역의 자기조직화 패턴이 다르다는 것을 시사한다. 즉, 인구밀집도가 높은 서울에서의 거리두기 효과가 경기도보다 저조할 경우, 연결의 빈도가 높은 네트워크 상의 자기조직화 현상으로 말미암아 정책효과의 불확실성이 더 강하게 존재함을 증명한다. 서울과 경기도를 비교 대상으로 선정한 것은 바로 이러한 이유에서며, 서로 인구 규모도 엇비슷한 등 여타 조건이 유사하여 정책효과를 뚜렷하게 비교할 수 있기 때문이다.

거리두기 단계를 2.5단계로 격상하기로 발표하였다(박찬범, 2020; 이덕영, 2020). 사회적 거리두기가 2.5단계로 격상됨에 따라 영업금지 업종이 기존 유흥시설 5종에서 노래방, 실내체육시설, 학원 등이 추가되었으며, 50인 이상 모임 금지, 대형마트, 영화관 등의 영업시간 제한되었다.

수도권 외 지역은 거리두기 2단계로 격상하는 등 전국 모든 지역에서 또한 사회적 거리두기가 실시되었다. 하지만 수도권에 한정하여 더 엄격한 거리두기 정책을 실시하였다는 점을 고려하여 비수도권과 정책적 차이가 있다는 가정하에 14개의 비수도권 지역을 이용하여 서울과 경기도에 대한 가상의 통제집단을 각각 생성하였다.¹²⁾

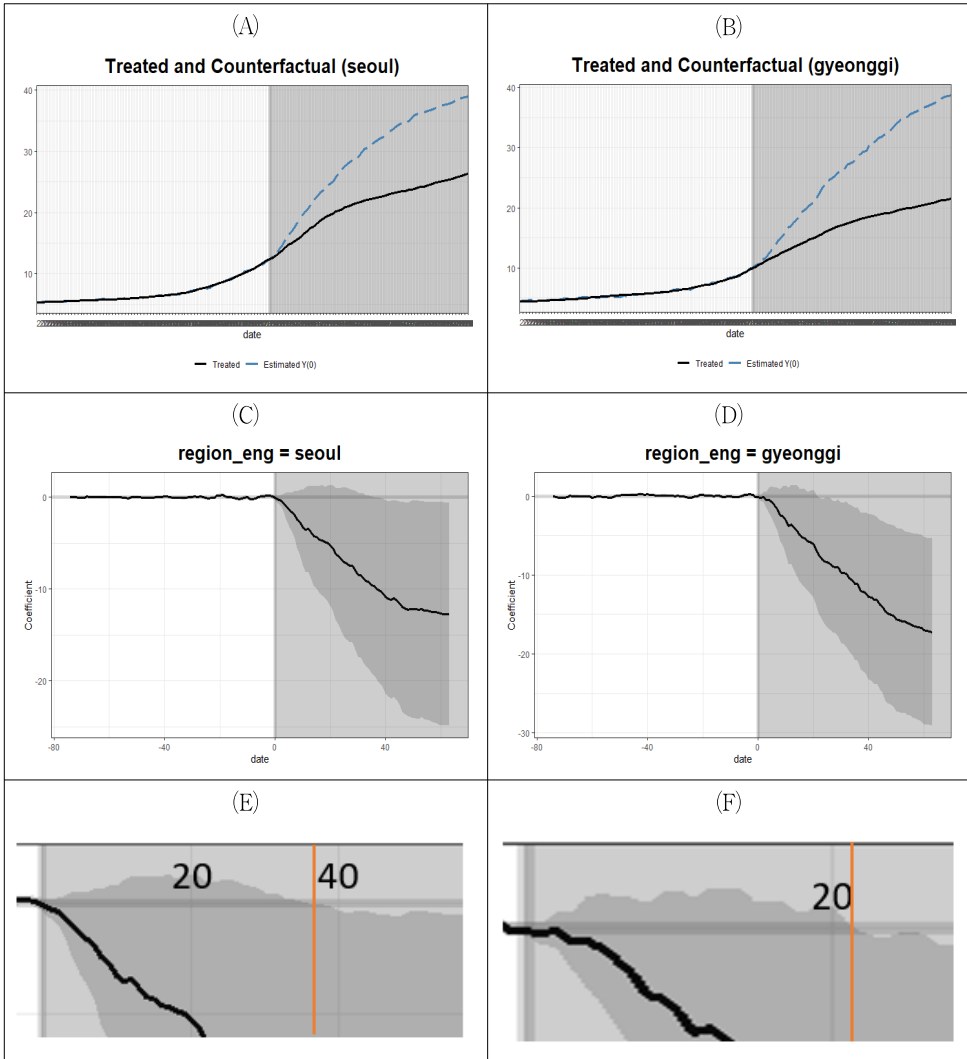
코로나바이러스의 잠복기로 인해 정책효과가 즉각적으로 나타나지 않기 때문에 (Goodman-Bacon and Marcus, 2020), 거리두기 정책 시행일은 12월 8일이지만, 정책효과가 발현되는 시기(post-treatment period)를 동월 15일로 설정하였다. 코로나바이러스의 잠복기간은 4일에서 7일 정도로 예상하기 때문에(Lauer et al., 2020; Li et al., 2020), 거리두기 시행일로부터 7일 후를 정책효과 발현 시작일로 가정하였다. 따라서 본 연구는 2020년 10월 1일부터 2021년 2월 15일까지의 기간 중 12월 15일을 기준으로 하여,¹³⁾ 이전 시기는 정책효과가 발현되지 않은 시기(pre-treatment period), 그 이후 시기는 정책효과가 발현되는 시기(post-treatment period)로 구분하였다.

정책효과를 분석하기 위해서 본 연구는 일별 누적 확진자수(천 명당)의 변화를 분석하였으며, 이때 사망자 수, 10만명당 발생률을 시간가변 공변수(time-varying covariates)로 사용하다. GSCM을 분석하기 위하여 R 4.1.2버전에서 Xu and Liu (2021)가 개발한 gsynth 패키지를 활용하였다. 데이터는 이전 장과 동일하게 공공데이터 포털에서 제공하는 “코로나19 시도발생 현황” 데이터를 이용하였다.

12) DID의 경우, 분석하고자 하는 개입의 효과가 통제집단에 영향을 미치면 안 된다고 가정하고 있지만, DID와 달리 GSCM은 개입 이전의 추세에 대해 반복적인 가중치를 계산하여 가상의 처치 집단의 추세를 설계하기 때문에, 다른 개입의 효과도 유연하게 반영할 수 있다(Mader and Ruttenauer, 2021).

13) 처리 전 데이터(pretreatment data)가 충분히 확보되어야 하기 때문에(Xu, 2012), 연구기간은 2020년 10월 1일부터 2.5단계가 끝나는 시점인 2021년 2월 15일까지로 설정하였다.

〈그림 6〉 서울/경기도의 거리두기 효과



주: 각 그림별 우측의 어두운 부분은 후 처리기간(posttreatment period)을 의미

패널 E와 F는 유의한 차이가 발생하는 시점을 중심으로 각각 C와 D를 확대한 결과이며, 주황색 실선은 유의한 차이가 나타나는 시점을 의미.

위 그림은 서울과 경기도를 대상으로 각각 GSCM을 분석한 결과이다. 분석결과 서울과 경기도 모두 거리두기 정책효과가 발생한 것으로 나타났다. 〈그림 6〉의 패널 A와 B의 검은색 실선은 각각 서울과 경기도의 천명 당 일별 누적 확진자수를 의미하며, 파란색 점선은 각각 가상의 서울과 경기도의 천명 당 일별 누적 확진자수를 나타낸다. 두 지역 모두 파란색 점선이 검은색 실선보다 가파르게 상승하는 모양은 거리

두기 정책효과로 인해 누적 확진자수가 실제로 감소한 것을 나타낸다.

하지만 정책효과의 정도 측면에서 서울과 경기도 간 차이가 있는 것으로 나타났다. <그림 6>의 패널 A와 B와 같이 경기도가 서울보다 더 큰 폭으로 감소하였으며, 경기도의 평균 ATT 또한 -9.765를 기록하며, 서울 -8.013보다 높게 기록되었다.

<그림 6>의 패널 C와 D는 일별 ATT가 어떻게 변화하는지 나타내고 있다. 검은색 실선이 일별 ATT이며, 검은색 실선을 중심으로 형성된 회색 부분은 1,000번의 부트스트랩을 통해 형성된 신뢰구간을 의미한다. 분석 결과 서울과 경기도 모두 일정 시점 후 가상의 통제집단과 유의한 차이를 보여 두 지역 모두 거리두기 정책의 효과가 나타났다. 그러나 유의수준 0.05 기준, 유의한 차이가 나타나기까지 서울은 37일이 소요되었으나 경기도는 22일이 소요된 것으로 나타났다.¹⁴⁾

GSCM은 충분한 통제집단의 수를 확보하지 않으면 결과값 왜곡에 대한 우려가 존재한다(Xu, 2017). 이를 보완하기 위해 이원고정효과모형(two-way fixed effect model) 기반의 DID를 활용한 2차 검증을 실시하였다(Bischof and Wagner, 2019; Zhao and Niango, 2021). DID를 활용하여 거리두기 정책에 따른 코로나 확산이 얼마나 완화되었는지 분석하기 위해서는 정책효과 발현 시점에 대해 GSCM보다 면밀한 조사가 필요하다. 따라서 특정 하나의 시점을 기준으로 개입 발생 전후를 구분한 기존 DID모델에서 Dave et al. (2021)은 다양한 구간이 포함될 수 있도록 모델을 사용하였다. 분석된 각 구간의 계수를 통해 어떤 시점에서 어떤 정책효과가 나타났는지에 대한 분석이 가능해짐으로써, 전 구간과의 비교를 통해 정책효과의 유의성을 추정할 수 있다. 본 연구는 DID분석을 위해 다음과 같은 모델을 사용하였다.

$$Y_{r,t} = \beta_0 + \sum_{i=1}^8 \beta_i Time_i \times Treat + \zeta_r + \delta_t + Z_r + \epsilon_{r,t}$$

거리두기가 실시된 12월 8일을 기준으로 3일간의 간격으로 8개 구간을 구분하였고, $Time_i$ 는 8개의 구간 중 i 구간에 해당하는 기간인 경우에는 1으로 정의한 더미변수이다. 즉, $Time_1$ 은 12월 8일부터 동월 10일까지를 1로, $Time_2$ 는 12월 11일부터 동월 13일까지를 1로 정의한 더미변수이다. $Time_8$ 은 12월 29일 이후의 모든 기간을 1로 정의하였다. $Treat$ 는 서울(또는 경기도)이면 1, 그 외 14개의 광역시도면 0으로

14) GSCM분석결과에 대한 표는 부록 참조.

정의되는 더미변수이다. 거리두기 정책과 상관없이 수도권외의 경우, 타 지역보다 신규 확진자 규모 측면에서 큰 차이를 보이기 때문에, β 를 통해 직접적인 거리두기 정책효과를 해석하기에는 한계가 있다. 대신, 이전 구간과의 비교를 통해 증가추세의 변화가 있었는지 분석함으로써, 거리두기 정책효과 발생시기를 추정하였다.¹⁵⁾

$Y_{r,t}$ 는 t 시기에 r 지역에서 발생한 일일 신규 확진자수를 의미한다.¹⁶⁾ ζ_r 와 δ_t 는 각각 지역·시간고정효과를 나타낸다. Z_r 는 코로나 확산에 영향을 미칠 수 있는 도시 특성을 나타내는 변수로, 인구규모(pop_no), 인구밀도(pop_den), 도시거주인구비율(urbanicity)을 의미하며(Cho, 2020; Friedson et al., 2020), 인구규모와 인구밀도는 로그값으로 치환하여 사용하였다.

분석을 위해 사용된 코로나 관련 데이터는 이전 장과 동일하게 공공데이터 포털에서 제공하는 “코로나19 시도발생 현황” 데이터를 이용하였으며, 도시 특성 관련 데이터는 통계청에서 제공하는 데이터를 활용하였다. 분석기간은 2020년 11월 1일부터 2021년 1월 31일까지이다.

DID 분석결과는 아래 <표 5>와 같다.¹⁷⁾ 모델1과 모델4는 고정효과를 고려하지 않은 일반회귀분석 모델이며, 그 외 모델은 고정효과를 반영한 모델이다. 고정효과를 고려하고 통제변수도 포함한 모델3과 모델6을 중심으로 이전 구간 대비 일일 신규 확진자가 얼마나 감소하였는지 분석한 결과, DID에서 또한 서울이 경기도보다 거리두기 정책효과가 늦게 발생한 것으로 나타났다.

15) Dave et al. (2021)은 이전 구간과의 비교를 통해 특정 구간에서의 정책효과 정도의 차이를 설명하였다. 이를 참조하여 본 연구도 두 개 구간의 계수 비교를 통해 정책효과에 따라 일일 신규 확진자수 증가추세가 언제부터 감소하였는지 추정하였다. 동일 모델 내 두 계수 간 유의한 차이가 있는지 분석하기 위하여 다음과 같이 t 검정을 실시하였다(Anderson and Armstrong II, 2021). 이때, $b_i - b_{i-1}$ 는 i 구간과 $i-1$ 구간의 계수 차이를 의미하며, $se(b_i - b_{i-1})$ 은 $b_i - b_{i-1}$ 의 표준편차를 의미한다.

$$t = (b_i - b_{i-1}) / se(b_i - b_{i-1})$$

16) 거리두기 정책 실시 전후 모든 시점에서 처치집단(서울 및 경기도)이 통제집단보다 누적 확진자수가 많았기 때문에, GSCM과 동일하게 DID에서 누적 확진자수를 종속변수로 활용할 경우 해석가능한 결과를 도출하는데 한계가 있다. 따라서 DID분석을 위해서 사용된 종속변수는 관련 선행연구를 참조하여 일일 신규 확진자수를 활용하였다(Dave et al., 2021)

17) 공통추세와 통제집단에 대한 다른 개입의 존재 등으로 인해 DID의 기본가정을 충족하지 못하기 때문에, 본 결과의 해석에 유의하여야 한다(Bischof and Wagner, 2019; Zhao and Niango, 2020).

〈표 5〉 DID분석결과

구분	서울			경기도		
	(1)	(2)	(3)	(4)	(5)	(6)
Treat*Time1	116.996*** (15.333)	116.996*** (17.087)	116.996*** (17.087)	109.519*** (10.960)	109.519*** (19.415)	109.519*** (19.415)
Treat*Time2	208.949*** (15.333)	208.949*** (36.535)	208.949*** (36.535)	191.804*** (10.960)	191.804*** (24.781)	191.804*** (24.781)
Treat*Time3	148.853*** (15.333)	148.853*** (39.431)	148.853*** (39.431)	186.376*** (10.960)	186.376*** (23.517)	186.376*** (23.517)
Treat*Time4	266.425*** (15.333)	266.425*** (17.025)	266.425*** (17.025)	196.947*** (10.960)	196.947*** (12.828)	196.947*** (12.828)
Treat*Time5	237.282*** (15.333)	237.282*** (42.657)	237.282*** (42.657)	137.804*** (10.960)	137.804*** (15.522)	137.804*** (15.522)
Treat*Time6	277.091*** (15.333)	277.091*** (58.553)	277.091*** (58.553)	186.281*** (10.960)	186.281*** (12.527)	186.281*** (12.527)
Treat*Time7	238.234*** (15.333)	238.234*** (38.439)	238.234*** (38.439)	137.090*** (10.960)	137.090*** (15.937)	137.090*** (15.937)
Treat*Time8	62.901*** (6.116)	62.901*** (20.667)	62.901*** (20.666)	93.393*** (4.337)	93.393*** (12.517)	93.393*** (12.517)
log(pop_no)	-	-	18.468*** (1.315)	-	-	18.468*** (1.315)
log(pop_density)	-	-	0.021 (1.040)	-	-	0.021 (1.040)
urbanicity	-	-	3.807 (5.257)	-	-	3.807 (5.257)
Time FE	NO	YES	YES	NO	YES	YES
Region FE	NO	YES	YES	NO	YES	YES
Observations	1380D	1380	1380	1380	1380	1380

주: 괄호 안은 표준편차(standard error)를 의미하며, 동 표준편차는 지역 간 이질적 특성을 고려함
(standard error clustered by region)

범주: ** $p < .05$, *** $p < .01$.

서울의 경우, 마지막 구간(12월29일~)의 신규 확진자가 전 구간(12월26~28일)에 비해 76.4% 감소하는 등 거리두기 정책효과가 발생하기 시작한 것으로 추정되었다.¹⁸⁾ 경기도의 경우 다섯 번째 구간(12월20일~22일)의 신규확진자가 직전 구간보다

18) 이전 구간 대비 유의한 감소의 판단 근거로 사용한 t 검정에 대해 모델 3을 예시로 설명하면 다음과 같다. 모델 3의 b_7 과 b_8 은 각각 238.234, 62.901이며, 해당 계수의 분산은 1477.556, 427.114이다. 그리고 공분산 행렬을 통해 추정된 두 계수 간의 공분산은 141.490이기 때문에, t 검정 결과는 -4.353로, 두 계수 간 유의한 차이가 존재한다.

유의한 차이로 약 30.0% 감소하였다. 그 후 다시 상승하였다가, 이후 두 개의 구간은 전 구간 대비 유의한 차이로 신규확진자가 감소하였다.¹⁹⁾

유의미한 차이는 아니었지만, 서울과 경기도 모두 세 번째 구간에서 이전 구간 대비 감소하였다가 다시 증가한 것으로 나타났다. 이는 두 수도권 지역에서 정책효과에 따른 신규확진자가 감소한 것보다는 타 지역에서 신규확진자가 폭증하였기 때문으로 추정된다. 해당 구간은 12월14일-16일까지의 구간인데, 동구간 내에 울산과 부산, 보령 등에서 병원과 학교를 중심으로 집단감염이 발생하였기 때문인 것으로 추정된다(오수희, 2020; 송인걸, 2020; 정세홍, 2020)

경기도의 경우, 여섯 번째 구간을 제외한 다섯 번째 구간부터 감소하였다. 여섯 번째 구간의 경우, 2020년 12월 23일부터 2020년 12월 25일까지의 구간인데, 해당 기간 동안 경기도 광주 내 육류가공업체, 파주의 복지시설, 서울구치소 등 특정 시설 관련 집단 감염으로 인해 큰 폭으로 상승하였다가 다시 감소추세를 보인 것으로 추정된다(이진경·김선영, 2020; 최준영, 2020; 주간현대, 2020).

지금까지 ‘사회적 거리두기’라는 동일한 정책이라도 서울과 경기도가 다른 정책 결과가 도출되었음을 보았다. 서울이 비록 인구규모 면에서 경기도보다 적지만 인구밀도가 높아 개인 간 접촉 확률이 훨씬 높다. 따라서 사회적 거리두기 2.5단계라는 동일한 정책을 실시하더라도 경기도보다 서울에서 그 효과가 훨씬 더디게 나타난 것이다. 평소 확진자가 늘 서울이 경기도보다 높게 나타난 이유이기도 하다. 이는 지역마다 상이한 인구규모와 인구밀도와 같은 네트워크 구조를 고려한 정책을 실시해야 소기의 정책 목적을 달성할 수 있으며, 동시에 국토의 네트워크 구조의 변화를 동반하지 않는 정책 또한 제대로 작동될 수 없음을 시사한다.

IV. 결 론

지금까지 확진자 분포가 두꺼운 꼬리의 멱함수 분포를 보이고 있음을 밝힘으로써 인구분포 이상의 휘발성을 지니고 있음을 알 수 있었다. 수도권처럼 인구가 밀집된

19) DID모형은 통제변수들 간의 내생적 문제를 통제하지 못하는 한계가 있어, 이를 보완하기 위해 본 연구는 추가적으로 상충차이모형(Difference in Difference in Differences, DDD)을 통해 도시 간 특성의 차이가 거리두기 정책효과에 작용하는 체계적인 차이(systematic difference)를 식별하고자 하였다(이정화, 2014). DDD 분석결과 또한 경기도에서 거리두기 정책효과가 먼저 발생한 것으로 나타났다. DDD 분석결과에 대한 자세한 설명은 부록 참조.

네트워크 환경에서는 구성원들 간의 연결 확률이 타 지역에 비해 유달리 높으며, 더불어 높은 구성원들의 연결 확률은 평균에서 매우 동떨어진 높은 확진자수를 창발시킬 수 있음을 보았다. 또한 이러한 네트워크 구조하에서는 확진자 발생을 통제하기 위한 정책 또한 의도대로 작동되지 않음을 사회적 거리두기 정책의 효과 분석을 통해 알 수 있었다.

어떤 사건이나 사태가 특정 네트워크 하에서는 극단적인 사태가 발현할 수 있으며, 해당 네트워크 구조가 바뀌지 않는 상황에서 사태를 진정시키기 위한 정책은 그 효과가 낮다는 의미이다. 본 연구는 그러한 측면에서 기존의 경제 현상에 대한 접근과 정책에 몇 가지 시사점을 제공한다.

첫째, 사회·경제적 현상에 대한 이해도를 넓히고 정책효과를 높이기 위한 복잡계 네트워크 접근의 필요성이다. 전통적인 경제학은 대개 정규분포(얇은 꼬리)를 가정하고 이론과 실증분석을 전개한다. 계량경제학에서는 정규분포 가정 하에 변수들 간에 인과관계를 분석하거나 편익-분석을 통해 최적의 정책을 제시하는 데 초점을 두고 있다. 하지만 이와 같은 전통적인 접근법은 본 연구결과와 같이 멱함수분포 하의 소수를 중심으로 발생하는 극단적인 사례를 고려하는데 한계가 있으며, 또한 정책효과의 이질성을 반영하지 못한다. 아직까지 복잡계 네트워크의 개념과 특성이 학자마다 다양하게 정의되고 있지만, 이들이 복잡계 네트워크 접근방법을 제시하는 과정에서 공통으로 고려하는 것은 보편적·최적의 정책이 존재하기 어렵다는 점이다. 자기조직화로 인해 동일 정책이라도 조직·지역마다 해당 정책의 효과가 상이할 수 있으며, 동일 지역으로 한정하여도 시뮬레이션 결과가 다르게 나올 수 있기 때문이다. 복잡해지고 불확실성이 높은 현대의 경제사회시스템에서 위험을 관리하는 차원의 복잡계 네트워크적인 접근방법을 고려할 필요가 있다.

둘째, 장기적인 관점에서 향후 코로나19와 같은 전염병이 발생하였을 때 이를 효과적으로 대응하기 위해서는 분산시스템이 뒷받침되어야 한다. 집중시스템 하에서는 확진자가 폭발적으로 늘어나 의료인력, 장비가 감당할 수 없는 의료체계 붕괴라는 소위 시스템 실패의 가능성이 훨씬 높아진다. 동일한 정책이라도 인구밀집도가 높은 지역일수록 이질적 정책효과가 나타나기 때문에 정책의 불확실성 해소를 위한 인구 과밀화 문제의 해결이 선행되어야 함을 시사한다. 다시 말해 네트워크 구조가 변하지 않는 상황에서 정책 소기의 목적을 달성하기 어려우며 오히려 해당 정책의 목표와 정반대의 결과를 초래할 수 있다. 코로나 확진자수뿐만 아니라 부동산 가격을 포함한 금융·경제 등 다양한 영역에서 수도권을 중심으로 폭증하는 현상 또한 복잡계 네트

워크 현상과 무관하지 않으므로, 정책의 불확실성을 해소하기 위한 분산시스템 구축이 필요하다.

셋째, 코로나19 사태 이후 ‘사회적 거리두기’가 우리에게 익숙해졌다. 개인들 간 접촉의 빈도를 줄이는 것은 강한 연결(strong tie)이 아닌 약한 연결(weak tie)을 통해 코로나 확산을 차단하려는 의도이다. 마찬가지로 경제 거래도 이전과는 다르게 국가 간 강한 연결이 아닌 약한 연결이 불가피하다. ‘위드 코로나’로 가는 과정에서 경험하고 있는 공급망 차질 문제 또한 과잉 네트워크에 대한 경고음을 우리에게 들려준다. 소위 세계화, 자유무역의 기치 아래 경제활동의 글로벌화가 초래한 위험성을 코로나 경험이 일깨워주고 있다. 언제라도 경제가 안보 수단이 될 수 있기 때문에 이에 대한 철저한 대비가 필요하다.

정부의 정책은 시장기능이 잘 작동할 수 있도록 환경을 만드는 일에 꾸준히 힘써야 함을 본 연구는 시사한다. 따라서 인구분포의 분산을 통해 개인들 간 연결 확률의 편차를 줄이는 것이 매우 중요하고, 그 위에 백신 접종과 사회적 거리두기와 같은 코로나 정책이나 부동산 시장 안정화 정책들이 실질적 효과를 거둘 수 있을 것이다.

본 연구는 인구분포에 대비한 확진자 분포의 특성을 네트워크 구조 유형을 통해 분석하고 경제 현상에 대한 복잡계 네트워크 접근의 필요성을 제시한 점에서 단순하면서 뚜렷한 시사점을 제시하고 있다. 향후 접촉자 수, 감염률, 인구밀도, 이동 패턴 등을 고려한 개인 네트워크 단위의 확진자 발생 모델 제시와 더불어 시뮬레이션을 수행한다면 좀 더 이론적 토대가 튼튼한 연구가 될 것으로 기대된다.

■ 참 고 문 헌

1. 김범준, 『복잡계 워크샵 - 복잡계로서의 사회와 사회물리학』, 삼성경제연구소, 2006.
2. 박찬범, “수도권 사회적 거리두기 2.5단계로 격상,” SBS, 2020년 12월 6일.
3. “보건복지부 코로나19 시도발생 현황”, 공공데이터포털, 2021년 12월 16일 접속, <https://www.data.go.kr/data/15043378/openapi.do>
4. 송인걸, “보령 아주자동차대학 21명 집단감염... 모두 외국인 유학생,” 한겨레, 2020년 12월 16일.
5. 오수희, “부산 인창요양병원 11명 추가... 감염경로 불명 n차 감염 ↑,” 연합뉴스, 2020년 12월 16일.
6. 이덕영, “신규 확진 594명... 오늘부터 수도권 2.5단계,” MBC, 2020년 12월 8일.
7. 이진경·김선영, “아파트형 구조·실내생활·고밀도... 대규모 추가 감염 불러,” 세계일보, 2020년 12월 25일.
8. 정세홍, “울산 코로나 환자 폭증... 일부 경주 양남으로,” 경상일보, 2020년 12월 16일.

9. 주간현대, “구치소 확산폭발...이명박, 박근혜도 검사,” 주간현대, 2020년 12월 24일.
10. 최준영, “어제 신규확진자 985명...논산 육군훈련소 11명 양성 판정,” 문화일보, 2020년 12월 24일.
11. Abadie, A., A. Diamond and J. Hainmueller, “Synthetic Control Methods for Comparative Case Studies: Estimating the Effect of California’s Tobacco Control Program,” *Journal of the American Statistical Association*, Vol. 105, No. 490, 2010, pp.493-505.
12. Alstott, J., E. Bullmore and D. Plenz, “Powerlaw: A Python Package for Analysis of Heavy-Tailed Distributions,” *PloS one*, Vol. 9, No. 1, 2014, pp.e85777.
13. Anderson, R. and D. A., Armstrong II, *Presenting Statistical Results Effectively*, SAGE Publications, 2021.
14. Arthur, W. B., “Competing Technologies, Increasing Returns, and Lock-in by Historical Events,” *The Economic Journal*, Vol. 99, No. 394, 1989, pp.116-131.
15. _____, “Positive Feedbacks in the Economy,” *Scientific American*, Vol. 262, No. 2, 1990, pp.92-99.
16. _____, “Increasing Returns and the New World of Business,” *Harvard Business Review*, Vol. 74, No. 4, 1996.
17. Barabási, A. -L. and R. Albert, “Emergence of Scaling in Random Networks,” *Science*, Vol. 286, No. 5439, 1999, pp.509-512.
18. Barabási, A. -L. and E. Bonabeau, “Scale-Free Networks,” *Scientific American*, Vol. 288, No. 5, 2003, pp.60-69.
19. Becerra, Ó., N. Johnson, P. Meier, J. Restrepo and M. Spagat, “Natural Disasters, Casualties and Power Laws: A Comparative Analysis with Armed Conflict,” *Proceedings of the Annual Meeting of the American Political Science Association*, Vol. No. 2012,
20. Beck, P. J. and G. S. Narayanamoorthy, “Did the Sec Impact Banks’ Loan Loss Reserve Policies and Their Informativeness?” *Journal of Accounting and Economics*, Vol. 56, No. 2-3, 2013, pp.42-65.
21. Benhabib, J. and A. Bisin, “Skewed Wealth Distributions: Theory and Empirics,” *Journal of Economic Literature*, Vol. 56, No. 4, 2018, pp.1261-1291.
22. Bettencourt, L. M., “The Origins of Scaling in Cities,” *Science*, Vol. 340, No. 6139, 2013, pp.1438-1441
23. Bischof, D. and M. Wagner, “Do Voters Polarize When Radical Parties Enter Parliament?” *American Journal of Political Science*, Vol. 63, No. 4, 2019, pp.888-904.
24. Born, B., Dietrich A. and G. J. Müller, “Do Lockdowns Work? A Counterfactual for Sweden,” *Covid Economics*, Vol. 16, No. 2020, pp.1-22.
25. Broido, A. D. and A. Clauset, “Scale-Free Networks Are Rare,” *Nature Communications*, Vol. 10, No. 1, 2019, pp.1-10.
26. Butler, M. J. and P. M. Allen, “Understanding Policy Implementation Processes as Self-Organizing Systems,” *Public Management Review*, Vol. 10, No. 3, 2008, pp.421-440.
27. Cai, X., Y. Lu, M. Wu, and L. Yu, “Does Environmental Regulation Drive Away Inbound Foreign Direct Investment? Evidence from a Quasi-Natural Experiment in China,” *Journal of Development Economics*, No.123, 2016, pp.73-85.

28. Cairney, P., "Complexity Theory in Political Science and Public Policy," *Political Studies Review*, Vol. 10, No. 3, 2012, pp.346-358.
29. Castelnovo, W. and M. Sorrentino, "Engaging with Complexity in a Public Programme Implementation," *Public Management Review*, Vol. 20, No. 7, 2018, pp.1013-1031.
30. Cho, S.-W., "Quantifying the Impact of Nonpharmaceutical Interventions During the Covid-19 Outbreak: The Case of Sweden," *The Econometrics Journal*, Vol. 23, No. 3, 2020, pp. 323-344.
31. Clauset, A., C. R. Shalizi and M. E. Newman, "Power-Law Distributions in Empirical Data," *SIAM Review*, Vol. 51, No. 4, 2009, pp.661-703.
32. Conyon, M. J., L. He and S. Thomsen, "Lockdowns and Covid-19 Deaths in Scandinavia," Available at SSRN 3616969, 2020.
33. Danon, L., T. A. House, J. M. Read and M. J. Keeling, "Social Encounter Networks: Collective Properties and Disease Transmission," *Journal of The Royal Society Interface*, Vol. 9, No. 76, 2012, pp.2826-2833.
34. Duxbury, S. W. and D. L. Haynie, "Building Them up, Breaking Them Down: Topology, Vendor Selection Patterns, and a Digital Drug Market's Robustness to Disruption," *Social Networks*, Vol. 52, No. 2018, pp.238-250.
35. Eppel, E., A. Matheson and M. Walton, "Applying Complexity Theory to New Zealand Public Policy: Principles for Practice," *Policy Quarterly*, Vol. 7, No. 1, 2011.
36. Erdős, P. and A. Rényi, "On the Evolution of Random Graphs," *The Structure and Dynamics of Networks*, Vol. No. 2011, pp.38-82.
37. Farber, D. A., "Probabilities Behaving Badly: Complexity Theory and Environmental Uncertainty," *UC Davis L. Rev.*, Vol. 37, 2003, pp.145.
38. Friedson, A. I., D. McNichols, J. J. Sabia and D. Dave, *Did California's Shelter-in-Place Order Work? Early Coronavirus-Related Public Health Effects*, National Bureau of Economic Research, 2020.
39. Goodman-Bacon, A. and J. Marcus, "Using Difference-in-Differences to Identify Causal Effects of Covid-19 Policies," 2020.
40. He, P. and B. Zhang, "Environmental Tax, Polluting Plants' Strategies and Effectiveness: Evidence from China," *Journal of Policy Analysis and Management*, Vol. 37, No. 3, 2018, pp. 493-520.
41. Hein, O., M. Schwind and W. König, "Scale-Free Networks," *Wirtschaftsinformatik*, Vol. 48, No. 4, 2006, pp.267-275.
42. Helbing, D., *Social Self-Organization: Agent-Based Simulations and Experiments to Study Emergent Social Behavior*, Springer, 2012.
43. Jackson, M. O. and B. W. Rogers, "Meeting Strangers and Friends of Friends: How Random are Social Networks?" *American Economic Review*, Vol. 97, No. 3, 2007, pp. 890-915.
44. Janczura, J. and R. Weron, "Black Swans or Dragon-Kings? A Simple Test for Deviations from the Power Law," *The European Physical Journal Special Topics*, Vol. 205, No. 1, 2012, pp.79-93.
45. Jo, H.-H. and Y.-I. Ko, "Large Variance and Fat Tail of Damage by Natural Disaster,"

- Vulnerability, Uncertainty, and Risk: Quantification, Mitigation, and Management, 2014, pp. 2744-2753.
46. Karoński, M. and A. Ruciński, The Origins of the Theory of Random Graphs. In: Graham R. L., Nešetřil J. (eds) The Mathematics of Paul Erdős I. Algorithms and Combinatorics, Vol. 13, Springer, 1997.
 47. Katz, M. L. and C. Shapiro, "Network Externalities, Competition, and Compatibility," *The American Economic Review*, Vol. 75, No. 3, 1985, pp. 424-440.
 48. Keeling, M. J. and K. T. Eames, "Networks and Epidemic Models," *Journal of the Royal Society Interface*, Vol. 2, No. 4, 2005, pp. 295-307.
 49. Klijn, E. -H., "Complexity Theory and Public Administration: What's New? Key Concepts in Complexity Theory Compared to Their Counterparts in Public Administration Research," *Public Management Review*, Vol. 10, No. 3, 2008, pp. 299-317.
 50. Kumar, R., J. Novak, P. Raghavan and A. Tomkins, "Structure and Evolution of Blogspace," *Communications of the ACM*, Vol. 47, No. 12, 2004, pp. 35-39.
 51. Lauer, S. A., K. H. Grantz, Q. Bi, F. K. Jones, Q. Zheng, H. R. Meredith, A. S. Azman, N. G. Reich and J. Lessler, "The Incubation Period of Coronavirus Disease 2019 (Covid-19) from Publicly Reported Confirmed Cases: Estimation and Application," *Annals of Internal Medicine*, Vol. 172, No. 9, 2020, pp. 577-582.
 52. Li, Q., X. Guan, P. Wu, X. Wang, L. Zhou, Y. Tong, R. Ren, K. S. Leung, E. H. Lau and J. Y. Wong, "Early Transmission Dynamics in Wuhan, China, of Novel Coronavirus-Infected Pneumonia," *New England Journal of Medicine*, Vol. No. 2020,
 53. Mader, S. and T. Rutenauer, "The Effects of Non-Pharmaceutical Interventions on COVID-19 Related Mortality: A Generalized Synthetic Control Approach Across 169 countries," 2021.
 54. Newman M. E., "Power Laws, Pareto Distributions and Zipf's Law," *Contemporary Physics*, Vol. 46, No. 5, 2005, pp. 323-351.
 55. _____, "Power Law Distribution," 2017, pp. 10-11.
 56. Nicolis, G. and I. Prigogine, "Exploring Complexity an Introduction," 1989.
 57. Pastor-Satorras, R. and A. Vespignani, "Epidemic Dynamics and Endemic States in Complex Networks," *Physical Review*, Vol. 63, No. 6, 2001, pp. 1-8.
 58. Schälpfer, M., L. M. Bettencourt, S. Grauwin, M. Raschke, R. Claxton, Z. Smoreda, GB. West, and C. Ratti, "The Scaling of Human Interactions with City Size," *Journal of the Royal Society Interface*, Vol. 11, No. 98, 2014, pp. 1-9.
 59. Su, D., M. Wen and K. S. Markides, "Is Self-Rated Health Comparable between Non-Hispanic Whites and Hispanics? Evidence from the Health and Retirement Study," *Journals of Gerontology Series B: Psychological Sciences and Social Sciences*, Vol. 68, No. 4, 2013, pp. 622-632.
 60. Tang, K., Y. Qiu, and D. Zhou, "Does Command-and-Control Regulation Promote Green Innovation Performance? Evidence from China's Industrial Enterprises," *Science of the Total Environment*, Vol. 712, 2020, pp. 1-10.
 61. Teisman G. R. and E. -H. Klijn, "Complexity Theory and Public Management: An Introduction," *Public Management Review*, Vol. 10, No. 3, 2008, pp. 287-297.

62. Tirole, J., *The Theory of Industrial Organization*, MIT Press, 1988.
63. Tizzoni, M., K. Sun, D., Benusiglio, M. Karsai, and N. Perra, "The Scaling of Human Contacts and Epidemic Processes in Metapopulation Networks," *Scientific Reports*, Vol. 5, No. 1, 2015, pp. 1-11.
64. Watts, D. J. and S. H. Strogatz, "Collective Dynamics of 'Small-World' networks," *Nature*, Vol. 393, No. 6684, 1998, pp. 440-442.
65. Weron, R., "Heavy-Tails and Regime-Switching in Electricity Prices," *Mathematical Methods of Operations Research*, Vol. 69, No. 3, 2009, pp. 457-473.
66. Xu, Y., "Generalized Synthetic Control Method: Causal Inference with Interactive Fixed Effects Models," *Political Analysis*, Vol. 25, No. 1, 2017, pp. 57-76.
67. Yip, M., N. Shadbolt and C. Webber, "Structural Analysis of Online Criminal Social Networks," 2012 IEEE International Conference on Intelligence and Security Informatics, Vol. No. 2012, pp. 60-65.
68. Zhang, K., D. Xu, S. Li, N. Zhou and J. Xiong, "Has China's Pilot Emissions Trading Scheme Influenced the Carbon Intensity of Output?" *International Journal of Environmental Research and Public Health*, Vol. 16, No. 10, 2019, pp. 1854.
69. Zhao, F. and R. A. Nianogo, "Medicaid Expansion's Impact on Emergency Department Use by State and Payer," *Value in Health*, 2021.
70. Zhou, B., Meng X. and H. E. Stanley, "Power-Law Distribution of Degree - Degree Distance: A Better Representation of the Scale-Free Property of Complex Networks," *Proceedings of the National Academy of Sciences*, Vol. 117, No. 26, 2020, pp. 14812-14818.

〈부록 1〉 GSCM 분석결과(서울)

시기	ATT (서울)	standard error	p-value
-74	0.0583	0.106	0.5809
-73	0.006	0.086	0.948
-72	-0.014	0.079	0.858
⋮	⋮	⋮	⋮
0	-0.029	0.134	0.830
1	-0.215	0.194	0.267
2	-0.344	0.311	0.269
⋮	⋮	⋮	⋮
32	-8.785	4.683	0.061
33	-9.104	4.744	0.055
34	-9.263	4.825	0.055
35	-9.572	4.920	0.052
36	-9.692	4.945	0.050
37	-10.02	5.079	0.048
38	-10.17	5.156	0.049
39	-10.41	5.241	0.047
40	-10.83	5.378	0.044
41	-11.05	5.4119	0.041

〈부록 2〉 GSCM 분석결과(경기도)

시기	ATT	standard error	p-value
-74	-0.0360	0.094	0.703
-73	-0.132	0.0765	0.0848
-72	-0.180	0.0708	0.011
⋮	⋮	⋮	⋮
0	-0.117	0.115	0.307
1	-0.185	0.189	0.329
2	-0.140	0.329	0.670
⋮	⋮	⋮	⋮
17	-5.343	3.191	0.094
18	-5.707	3.179	0.073
19	-5.856	3.356	0.081
20	-6.058	3.494	0.083
21	-6.806	3.576	0.057
22	-7.485	3.770	0.047
23	-8.018	3.869	0.038
24	-8.271	4.042	0.0407
25	-8.344	4.203	0.047
26	-8.563	4.257	0.044

〈부록 3〉 DDD 분석결과

본 연구에서 사용한 DID모형의 경우, 통제하는 변수들 간의 내생성을 통제하지 못하기 때문에 지역의 특성에 따라 상이한 결과를 야기할 수 있다. 또한 통제집단과 처치집단이 동일한 지역 내에서 구분된 것이 아니기 때문에, 통제변수로 활용한 도시특성에 의한 체계적인 차이를 식별하기 위하여 DDD분석을 추가로 실시하였다(He and Zhang, 2018; Cai et al., 2016; Fan et al., 2019; Tang et al., 2020).

$$Y_{r,t} = \gamma_0 + \sum_{i=1}^8 \gamma_i (Time_i \times Treat_r \times Z_r) + \zeta_r + \delta_t + \epsilon_{r,t}$$

$Treat_r$ 은 서울과 경기도인 경우를 1로, 그 외 14개의 광역도시면 0으로 정의된 더미변수이다. Z_r 은 이전 DID모형에서 통제변수로 활용되었던 도시특성변수를 의미한다. 그 외 변수는 이전 DID모형과 동일하다.

$\hat{\gamma}_i$ 를 통해 도시특성에 따른 거리두기 효과의 차이를 추정할 수 있다. 즉, $\hat{\gamma}_i$ 가 부(-)의 관계를 나타낸다면, 해당 도시특성의 값이 높을수록 거리두기 효과에 의해 신규 확진자수가 줄어든 것을 의미한다.

인구규모를 도시특성으로 정의하였을 때, 여섯 번째 구간 예외, 네 번째 구간부터 마지막 구간 전까지 유의한 부(-)의 관계가 있었다. 하지만 마지막 구간에서 유의한 정(+)의 관계가 있는 것으로 나타났다. 네 번째 구간부터 인구규모가 큰 지역, 즉 경기도에서 거리두기 정책효과에 따른 신규 확진자수 감소가 더 크게 나타났으며, 마지막 구간부터는 서울의 정책효과가 더 커진 것을 의미한다. 유의한 관계를 갖지 않은 여섯 번째 구간의 경우, 이전 DID분석 때 기술한 바와 같이, 경기도 내 시설 집단 감염으로 인해 확진자가 크게 증가하였기 때문인 것으로 추정된다. 마지막 구간에서 서울의 정책효과가 더 큰 것은 DID분석결과와 같이 그때부터 서울에서 거리두기 정책효과가 발생하였기 때문인 것으로 예상된다.

인구밀도와 도시거주인구비율을 도시특성으로 정의하였을 때, 인구규모와 반대의 결과가 도출되었다. 이는 인구규모가 큰 지역은 경기도인 반면, 인구밀도와 도시거주인구비율이 큰 지역은 서울이기 때문이다.

구분	인구규모	인구밀도	도시거주인구비율
Treat*Time1*Z	-54.169 (55.03)	1.763 (6.683)	105.391 (140.122)
Treat*Time2*Z	-134.673 (123.454)	5.393 (14.186)	256.320 (299.726)
Treat*Time3*Z	244.920 (141.982)	-38.106 (20.763)	-683.482 (370.458)
Treat*Time4*Z	-500.737*** (82.809)	64.062*** (9.937)	1244.066*** (209.663)
Treat*Time5*Z	-707.038*** (241.277)	95.601*** (32.721)	1794.207*** (623.522)
Treat*Time6*Z	-646.616 (458.486)	83.725 (62.983)	1634.153 (1204.287)
Treat*Time7*Z	-726.097*** (174.758)	97.869*** (25.359)	1857.957*** (466.946)
Treat*Time8*Z	198.681* (85.180)	-34.495*** (11.179)	-578.588*** (218.939)
Time FE	YES	YES	YES
Region FE	YES	YES	YES
Observations	1380	1380	1380

주: 괄호 안은 표준편차(standard error)를 의미하며, 동 표준편차는 지역 간 이질적 특성을 고려함
(standard error clustered by region).

범주: ** $p < .05$, *** $p < .01$.

Coronomics: Self-Organization Phenomenon in Complex Network

Inje Kang* · Duk Hee Lee**

Abstract

The skewed distribution has been observed in natural disaster, economy, and so on. The current high proportion of the COVID-19 confirmed cases in the Seoul Metropolitan Area seems to be its another case. The standard economics fails to explain them since it mainly assumes the normal distribution. Thus, this paper attempts to examine the pattern of COVID-19 cases occurrence in the framework of complex network and explore the uncertain effect of the social distancing policy. The results showed the distribution of COVID-19 cases followed a power law distribution with a fatter tail than the population distribution. Also we confirmed that the social distancing policy has a limited effect in the high population density area like Seoul Metropolitan Area because of the self-organization mechanism of large-scale network. This study implies that the complex network approach is necessary to better understand the contemporary socioeconomic system.

Key Words: power-law, self-organization, complex network, COVID-19 distribution, population distribution, scale-free network

JEL Classification: C8, C4, J1, D8

Received: Dec. 28, 2021. Revised: Feb. 18, 2022. Accepted: May 18, 2022.

* First Author, Graduate Student, School of Business and Technology Management, College of Business, Korea Advanced Institute of Science and Technology, 291, Daehak-ro, Yuseong-gu, Daejeon 34141, Korea, e-mail: ijkang@kaist.ac.kr

** Corresponding Author, Professor, School of Business and Technology Management, College of Business, Korea Advanced Institute of Science and Technology, 291, Daehak-ro, Yuseong-gu, Daejeon 34141, Korea, Phone: +82-42-350-6306, e-mail: dhlhexys@kaist.ac.kr