

머신러닝 기반의 수도권 지역 고령운전자 차대사람 사고심각도 분류 연구

김승훈¹, 임영빈², 김기정^{3*}

¹오하이오주립대학교, ²한국과학기술원, ³두원공과대학교

Classifying Severity of Senior Driver Accidents In Capital Regions Based on Machine Learning Algorithms

Seunghoon Kim¹, Youngbin Lym², Ki-Jung Kim^{3*}

¹City and Regional Planning, The Ohio State University

²Center for Innovation Strategy and Policy, KAIST

³Department of Smart Car Engineering, Doowon Technical University

요 약 고령화 시대에 따라 고령운전자 역시 증가하고 있으며, 이들에 의한 교통사고 심각성에 대한 관심이 높아지고 있다. 이에 고령운전자에 의한 사고심각도 예측 모형의 필요성이 점차 요구됨에 따라, 본 연구에서는 기계학습 기법을 활용하여 고령운전자에 의한 차대사람 사고심각도 예측을 위한 모형 정립 및 분석을 수행하고자 한다. 이를 위해 4개의 기계학습 알고리즘 (Logistic Model, KNN, RF, SVM)을 활용, 예측 모형을 개발하고 각 결과를 비교하였다. 연구 결과에 따르면 Logistic과 SVM 모형이 상대적으로 높은 예측력을 보였으며, 정확도 측면에서는 RF가 높은 것으로 나타났다. 추가적으로 각 중요 변수들을 이용하여 교차분석을 수행한 후 그 결과를 제시하였다. 본 연구의 결과들은 고령화시대에 고령운전자에 의한 사고심각성을 예방하기 위한 안전정책 및 인프라 개발에 활용될 것으로 판단된다.

주제어 : 교통사고분석, 고령운전자, 사고심각도, 기계학습, 분류

Abstract Moving toward an aged society, traffic accidents involving elderly drivers have also attracted broader public attention. A rapid increase of senior involvement in crashes calls for developing appropriate crash–severity prediction models specific to senior drivers. In that regard, this study leverages machine learning (ML) algorithms so as to predict the severity of vehicle–pedestrian collisions induced by elderly drivers. Specifically, four ML algorithms (i.e., Logistic model, K–nearest Neighbor (KNN), Random Forest (RF), and Support Vector Machine (SVM)) have been developed and compared. Our results show that Logistic model and SVM have outperformed their rivals in terms of the overall prediction accuracy, while precision measure exhibits in favor of RF. We also clarify that driver education and technology development would be effective countermeasures against severity risks of senior driver–induced collisions. These allow us to support informed decision making for policymakers to enhance public safety.

Key Words : Traffic accident analysis, Senior driver, Crash severity, Machine learning, Classification

*Corresponding Author : Ki-Jung Kim(kimkj@doowon.ac.kr)

Received January 26, 2021

Accepted April 20, 2021

Revised March 28, 2021

Published April 28, 2021

1. 서론

통계청에 따르면 2010년에는 65세 이상 고령화 인구 비율이 7.2%였지만, 2020년에는 우리나라 인구의 15.7%로 2배 이상 증가하였으며, 향후 2025년에는 20.3%에 이르러 우리나라가 초고령사회로 진입할 것으로 전망하고 있다[1]. 이러한 고령화 시대에 따라 65세 이상의 운전자 역시 증가하고 있으며 고령운전자의 인지 능력 저하로 인해 교통사고가 발생했을 때 심각한 인명 피해로 이어질 가능성이 크다[2].

2020년 경기연구원의 보고서에 따르면 전국 교통사고는 연평균 0.1%씩 감소하고 있지만, 65세 이상 고령운전자 교통사고 수는 2009년 1만 2000건에서 2019년 3만 3000건으로 2.7배 증가하였다. 특히 2019년 고령운전자에 의한 교통사고 사망자 수는 769명으로 전국 교통사고 사망자 수 3349명의 약 23%를 차지하고 있는 실정이다[3].

따라서 향후 지속적인 고령자 증가는 고령운전자의 교통수단 활용 증대로 이어질 것이라 예상되며, 고령운전자에 의한 사고특성과 그 유형에 대한 적절한 분석이 요구된다. 교통사고 분석은 일반적으로 사고빈도(frequency), 사고율(crash rate), 사고심각도(severity)의 측면을 고려하는데, 사고빈도와 사고율은 사고 통계의 상호 비교를 위해 사용되며, 사고심각도는 사망-중상-경상-대물피해 등을 판별하기 위한 목적으로 활용되고 있다[4,5]. 국내 고령운전자 사고 관련 선행연구를 살펴보면 대다수가 사고빈도에 관한 연구이며, 사고심각도 판별(분류)에 관한 연구는 다소 부족한 실정이다. 또한, 기계학습을 활용한 사고심각도의 분류(classification)에 대한 연구는 거의 없는 것으로 판단된다. 본 연구에서는 고령운전자에 의해 야기되는 보행자 피해의 사고심각도에 미치는 요인에 대한 분석을 수행하고자 하며, 이를 위해 기계학습 기반의 다양한 알고리즘을 활용하는 데 목적이 있다.

2. 선행 연구

2.1 고령운전자 교통사고 연구

기존 국내 고령운전자의 교통사고 분석 연구는 사고빈도에 관한 연구가 다수를 차지하고 있으며 주로 고령운전자의 신체적 특성과 운전행동에 따른 사고 영향성 분석을 다루고 있다[5-8]. 이들 연구에 따르면 고령운전자는 인지 부하 시 주행 속도를 줄이는 특성을 보이고, 속

도 제어 능력은 전반적으로 떨어지는 것으로 나타났으며, 사고특성의 경우 운전자 연령이 증가함에 따라 측면직각 충돌 사고위험도 함께 증가할 가능성이 있음을 주장하고 있다. 또한 고령운전자의 경우 주행 중 교통량, 주행속도, 도로유형 등 환경요인에 대한 심리적 부담감이 상대적으로 높으며, 도로 환경이 고령운전자의 교통사고 발생에 영향을 미치는 것으로 제시하였다[9-10]. 고령운전자에 대한 사고예방대책 측면에서는 고령자 연령별 대상의 특성에 따라 다각화하여 교육프로그램 및 법적 제도를 마련해 적절한 재교육 프로그램 및 고령 친화적인 도로환경 조성의 필요성을 제시하고 있다[11-13].

한편 교통사고 분석에 있어 다양한 사고모형이 개발되어 있으며, 사고빈도 분석에서는 기본적으로 일반화선형 모형에 기반을 둔 포아송 또는 음이항 회귀모형 이외 확률효과를 고려한 보다 복잡한 모형들이 적용되고 있다[14]. 사고심각도 측면에서는 사망, 중상, 경상 등을 판별하기 위해서 다양한 모형을 적용하여 연구를 수행해 오고 있는데, 주로 이항로짓과 프로빗 모형(binary logit and probit models)이 활용된다. 이 외에도 다항선택모형(Multinomial choice model) 및 Mixed logit 모형도 널리 활용되고 있다[15].

2.2 기계학습기반 교통사고 연구

최근 교통사고 분석에 있어 빅데이터 및 기계학습 기법을 적용하는 연구가 활발해지고 있다. 국내에서는 주로 의사결정나무(Decision Tree)와 데이터 간의 상대적 거리를 통해 분류하는 K-최근접 이웃(K-Nearest Neighbors, KNN) 등의 모형을 주로 사용하고 있다[16,17]. 해외에서는 로지스틱/프로빗 기반의 모형과 랜덤 포레스트(Random Forest, RF)와 같은 의사결정나무 기반의 모형, 부스팅 기반의 모형, Support Vector Machine (SVM), 및 딥러닝(Deep Learning) 기반의 모형 등을 이용하는 연구가 활발히 진행되고 있다[18-21]. 본 연구는 많은 방법론 중에서 일반적으로 널리 사용되는 방법론인 로지스틱 모형, KNN, RF, SVM을 선택하였다. 로지스틱 모형은 전통적인 분류 통계기법이며, KNN은 비모수 방식의 사례기반학습(instance-based learning), RF는 의사결정나무 알고리즘을 이용한 앙상블(ensemble learning) 방식을 채택하고 있다. 마지막으로 SVM은 비확률적 분류 알고리즘(non-probabilistic classifier) 기법으로, 본 연구는 이들 4가지 알고리즘을 적용하여 예측 분석을 수행하였다.

3. 연구방법 및 범위

3.1 연구 범위

본 연구의 목적은 고령운전자에 의해 야기된 보행자의 교통사고 심각도를 예측하기 위한 모형개발이다. 이를 위해 2015-2019년 서울과 경기 지역에서 발생한 고령운전자의 차대사람 사고를 주된 연구대상으로 고려하였다. 도로교통공단 교통사고관리시스템(TAAS)의 정의에 따라 고령 운전자의 연령은 65세 이상으로 설정하였으며 사람(보행자)의 연령제한은 하지 않았다.

3.2 연구 방법

모형개발을 위해 도로교통공단의 교통사고관리시스템(TAAS)의 고령운전자 사고자료의 전처리 작업을 수행하였다. 이 과정에서 종속변수(Target variable)인 보행자의 사고심각도와 몇몇 이산형 설명변수들에서 일부 범주(Class)가 너무 적게 나타났기 때문에, 재분류(Re-categorization)화를 통해 Class 간 불균형을 개선하였다. 우선 종속변수 중 사망과 중상사고를 하나의 항목으로 부상사고와 경상사고를 또 다른 하나의 항목으로 통합하여 재분류하였다. 다음으로, 설명변수 개별 항목을 자세히 검토 후 그 빈도가 너무 적게 나타난 도로경사, 고령 운전자와 보행자의 연령, 그리고 교통사고 발생 시간대와 계절 항목 변수를 재-범주화하였다. 결과적으로 전처리 후 최종 데이터 현황은 Table. 1과 같다.

이러한 데이터를 기반으로 다양한 머신러닝 알고리즘(다항 로지스틱 모형, RF, KNN, SVM)을 적용하여 고령운전자에 의한 사고심각도 예측 모형을 개발하였으며 전반적인 연구과정은 Fig. 1에 제시하였다. 구체적인 기계학습 알고리즘별 연구방법은 다음과 같다. 로지스틱 회귀 모형은 전통적인 확률론적 모형으로 종속변수가 이항 혹은 다항일 경우 사용할 수 있는데 본연구에서는 이항 로지스틱 회귀모형이 사용되었다. 이 모형은 0과 1로 구성된 종속변수가 1의 될 확률의 로그오즈(log-odds)값과 설명변수와의 선형관계를 가정하여 회귀분석을 수행한다. 그리고 변환된 확률값이 0.5 이상일 경우 종속변수값을 1로 예측한다[22]. K-최근접이웃(KNN) 알고리즘은 거리 행렬을 이용하여, 각 측정값에서 최대한 가까운 다른 K개의 측정값을 찾아 가장 많은 수의 측정값이 가지고 있는 종속변수의 계층값을 부여하고, 각 측정값 간 거리 행렬은 유클리디안 거리 함수로 계산되었다. 10-fold cross validation 결과 적합한 K값은 40으로 도출되었다[23]. SVM은 m개의 그룹(종속변수)과 n 개의 변수를

가지는 데이터의 입력 벡터 X를 n 차원의 특성 공간에 투영하고 m개의 그룹을 최적으로 구분할 수 있는 (m-1) 개의 초평면(optimal decision boundary, maximum margin hyperplane)을 찾아내는 작업을 수행한다. 또한, SVM은 커널 함수의 정의에 따라서 선형 혹은 비선형 초평면을 가지는데 본 연구에서는 Radial Basis Function(RBF) 커널 함수를 사용하였고 관련된 두 개의 파라미터 (penalty factor to errors, radius)=(0.5, 0.01116)가 10-fold cross validation 결과 선택되었다[24]. Breiman에 의해 개발된 RF는 앙상블 기법 중 하나이며, 부트스트래핑(bootstrapping)과 배깅(bagging)을 결합하여 다수의 의사결정 나무 모형을 개발한 후 다수의 의사결정나무의 예측에 따라 관측치의 계층을 부여한다. 각 의사결정나무를 학습할 때마다 데이터를 훈련데이터(Training set)와 검증데이터(Test set)로 랜덤으로 구분하며(bootstrapping), 변수 또한 랜덤으로 선택된다(bagging). 본 연구에서는 의사결정나무 개수를 1000개로 설정하고 10-fold cross validation을 수행한 결과 각 의사결정나무에는 3개의 변수 사용이 적절한 것으로 나타났다[25].

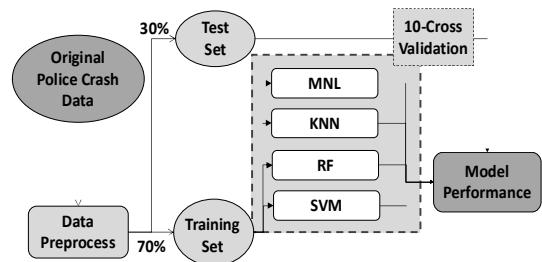


Fig. 1. Flow chart for analysis

4. 결과

4.1 모형학습 결과

훈련데이터와 10-fold cross validation을 통해 4가지 기계학습 알고리즘을 학습시켰다. 단, 로지스틱 모형의 경우 10-fold cross validation이 필요하지 않아 최적 매개변수 설정 과정에서 제외되었다. 또한 각 모형의 학습결과를 비교하기 위하여 훈련데이터를 대상으로 한 예측성능을 분석하였다. Fig. 2에 제시한 바와 같이 각 알고리즘의 학습 결과, 모든 예측성능 지표에서 RF가 뛰어난 것으로 나타났고 KNN이 가장 미흡한 것으로 나타났다.

Table 1. Descriptive Statistics

Variable	Data Type	Label	Frequency
Severity (Y)	Ordinal	Severe (including Fatal)	4779
		Slight (including Possible)	6199
Age (X1)	Ordinal	0 ~ 9	481
		10 ~ 19	922
		20 ~ 29	1504
		30 ~ 39	1197
		40 ~ 49	1379
		50 ~ 64	2818
		65 ~ 80	2098
		< 80	579
Gender (X2)	Nominal	Female	5660
		Male	5318
CrashType (Car_Person) (X3)	Nominal	Etc	3711
		Walking on the edge of the road	631
		On the sidewalk	517
		on the road	892
		walking across	5227
		etc	509
Violation (X4)	Nominal	Intersection	57
		Median	87
		Pedest	1785
		Safe distance	13
		Safe driving	7287
		Signal	1186
		Speeding	27
		Uturn	27
RoadSurface (X5)	Nominal	Dry	9967
		Etc	153
		Moisture	512
		Snow/ice	38
		Wet	308
Climate X6)	Nominal	Clear	9794
		Cloudy	423
		Etc	86
		Rain	642
RoadType (X7)	Nominal	Snow	33
		Overpass/Bridge/Tunnel /Underpass	61
		Single road_etc	5550
		Etc	645
		Near the intersection	1464
		Inside the intersection	1731
		Intersection/Within the crosswalk	949
		Parking lot	65
Single road /Within the crosswalk	72		

		Single road/Within the crosswalk	441
Region (X8)	Nominal	Gyeonggi-do	4536
		Seoul	6442
Vehicle Type (X9)	Nominal	Bicycle	342
		Bike	257
		Construct	36
		Etc	20
		Motorcycle	94
		Sedan	8090
		Truck	1075
Driver Gender (X10)	Nominal	Van	1064
		Male	1195
Crash Day (X11)	Nominal	Female	9783
		Fri	1743
		Mon	1693
		Sat	1374
		Sun	1111
		Thur	1670
		Tue	1672
		Wed	1715
Crash Season (X12)	Nominal	Fall	3084
		Spring	2706
		Summer	2434
		Winter	2754
Crash Time (X13)	Nominal	afternoon(12 ~ 18 hr)	3937
		Dawn(24 ~ 06 hr)	1400
		Morning(06 ~ 12 hr)	2904
		Night(18 ~ 24 hr)	2737
Driver Age (X14)	Ordinal	65 ~ 70	5901
		70 ~ 75	3254
		75 ~ 80	1413
		80+	410




Fig. 2. Comparison of predictive performance measures among machine learning algorithms (Training set)

4.2 모형 예측력 평가

훈련데이터와 10-fold cross validation을 통해 학습된 결과를 기반으로 검증데이터에 4가지 기계학습 알고리즘 모형의 예측 성능 평가를 수행하였다. 단, 로지스틱 모형의 경우 10-fold cross validation이 필요하지 않아 최적 매개변수 설정 과정에서 제외되었다. 모형의 예측 성능을 평가하기 위해 오분류표(Confusion matrix) 기반의 예측 성능 지표 (Precision, Recall/Sensitivity, F1, Accuracy)를 계산하였으며, 그 결과를 Fig. 3에 제시하였다. 분석결과를 살펴보면, 대체로 모형의 전체적인 예측력은 크게 차이가 없는 가운데 로지스틱 모형이 가장 우수한 것으로 나타났다. 하지만 precision의 경우 RF가 가장 우수하며, 로지스틱 모형이 상대적으로 낮은 것으로 나타났다. 이는 중상으로 예측된 사고가 실제 중상일 확률이 RF가 가장 높으며 로지스틱 모형은 그렇지 않다는 것을 의미한다. 이밖에 실제 중상 사고들을 중상으로 예측할 확률인 Recall/Sensitivity와 precision과 recall의 조화 평균인 F1 score는 로지스틱 모형이 가장 높은 것으로 나타났다.

4.3 사고심각도 영향 요인

RF의 변수 중요도 지표(Mean Decrease Gini)를 이용하여 보행자 사고심각도에 미치는 상위 중요 요인들을 파악하고, 그 결과를 Fig. 4에 제시하였다.

Fig. 4에 따르면, 사고에 영향을 미치는 중요 변수들은 보행자 연령, 사고 유형, 가해 운전자 연령, 법규위반,

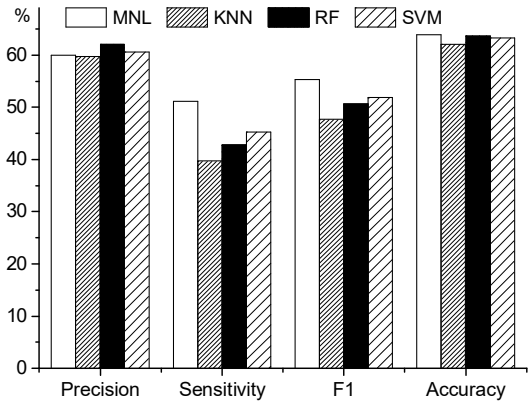


Fig. 3. Comparison of predictive performance measures among machine learning algorithms (Test set)

도로 형태 등으로 나타났다.

각 중요 변수들을 이용하여 교차분석을 시행한 결과, 첫째, 사고 유형의 경우, 차도 통행 중과 횡단 중에 일어난 사고의 중상 비중이 다른 유형의 사고 즉, 길거리 가장자리구역 통행 중, 보도통행 중 사고에 비해 높았다. 둘째, 고령운전자 법규위반 항목에서 과속, 신호위반, 그리고 보행자 보호의무 위반과 안전운전 불이행으로 인한 중상 비율이 다른 법규위반 사고에 비해 높았다. 셋째, 고령 가해 운전자 연령 별 중상 사고 비중은 75~80세 및 65~70세 집단에서 비교적 일정하며 고령 운전자일수록 사고 피해자의 중상 비중이 감소하는 경향을 보였다.

그 외에도 보행자 연령에 따른 중상피해 비중이 유의한 차이를 보였으며 오후 시간대의 사고가 다른 시간대

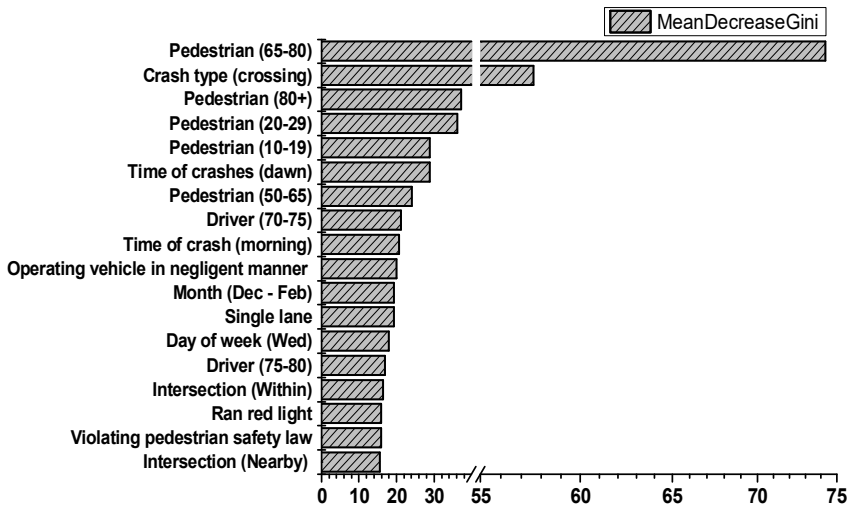


Fig. 4. Variable importance plot

의 사고보다 중상 비중이 낮았다.

5. 결론

본 연구에서는 고령운전자의 차대사람 사고자료를 수집하여 보행자 교통사고 심각도 예측 모델을 개발하였다. 자료 구축과정에서 종속 변수인 사고심각도의 일부 범주의 표본 수가 과소하여 재 범주화하였다. 모형 과적합을 방지하기 위해 훈련데이터와 검증데이터로 구분하고, 훈련데이터를 이용하여 모형을 개발한 후 이를 검증데이터에 적용하여 모형의 성능을 측정 비교하였다. 또한 RF 모델의 변수 중요도 지표와 교차분석을 이용하여 사고심각도에 영향을 주는 요인들을 분석하였다.

기계학습 모형들의 예측력 평가 결과, 전체적인 예측력은 로지스틱 회귀와 SVM 모형이 다른 모형들에 비해 상대적으로 우수한 것으로 나타났다. 하지만 세부적인 예측 성능을 고려하는 경우, 가령 중상으로 예측된 사고의 정확도에 중점을 둔다면, RF 모형이 다른 모형에 비해 우수한 성능을 보였다. 그러므로 예를 들어 긴급의료자원(구급차)의 효과적인 배분을 위해서라면 보행자의 부상 정도가 심각한 정도를 정확히 예측하는 것이 경미한 사고를 예측하는 것보다 중요하므로 RF모형 이용을 권장할 수 있다 하겠다.

사고심각도의 영향요인 분석 결과, 고령운전자가 차도 통행 중이거나 횡단 중인 보행자에게 야기하는 사고의 부상 정도가 심각한 것으로 나타났다. 이는 고령운전자에 의한 사고위험도를 줄이기 위해서는 공학적인 측면에서 차도를 통행하는 보행자를 인지하는 인공지능의 발달이 필요함을 시사한다. 또한, 고령운전자의 범규위반에 의한 사고심각도는 과속과 신호위반, 보행자 보호의무 위반, 안전운전 불이행 등이 높은 것으로 나타났다. 그러므로 고령운전자의 범규위반에 의한 사고를 감소시키기 위하여 안전운전교육의 필요성이 제기된다. 예를 들면 횡단보도 내에서의 보행자 보호 의무 규정과 같이 시대에 따라 적용 범위가 달라지는 법령 등이 있다. 또한, 고령운전자의 비교적 느린 반응속도와 인지속도를 고려하여 전방의 횡단보도 혹은 신호등에 접근할 경우 안내를 하는 서비스 등을 고려해 볼 수 있다.

본 연구의 한계점으로는 첫째, 보행자 부상심각도의 일부 범주가 과소하게 나타나 재범주화하였다는 것이다.

즉, 중상과 경상으로부터 구분한 본 연구의 모형은 보다 세부적인 부상 심각도의 예측을 불가능하게 하는 한계가

있다. 그러므로 차후 연구에서는 Synthetic Majority Oversampling Techique(SMOTE)과 같은 불균형 상태의 데이터를 분석할 수 있는 방법론의 적용이 필요하다. 또한, 현재 해외 연구 동향에서 많이 쓰이고 있는 심층학습(Deep Learning)과 같은 연구기법의 적용을 통해 예측력을 향상시킬 필요가 있다.

REFERENCES

- [1] Statistics Korea. (2020). Statistics on the Aged
- [2] J. J. Choi, J. S. Gim & T. H. Kim. (2017) Analyzing Driving Environment Effects on Severity of Elderly Driver's Traffic Accidents. *Journal of Transport Research* 24(1), 79-94. DOI : 10.34143/jtr.2017.24.1.79
- [3] Gyeonggi Research Institute. (2020). A study on the improvement of road traffic facilities for elderly drivers in a super-aged society
- [4] The Seoul Institute. (2019). A study on risk assessment techniques for prevention of road traffic accidents.
- [5] Korea Road Traffic Authority. (2012). Analysis of traffic accident characteristics and accident prevention measures for elderly drivers.
- [6] J. H. Kim, J. S. Oh & S. C. Lee. (2006). The Influences of Driving Behavior Determinants on Traffic Violations and Accidents. *Korean Society for Industrial and Organizational Psychology*. 19(3). 349-369.
- [7] J. S. Oh, E. Y. Lee, J. B. Ryu & W. Y. Lee. (2015). An Analysis for Main Vulnerable Situations and Human Errors of Elderly Drivers' Traffic Accidents. *Journal of Transport Research*. 22(4). 57-75. DOI : 10.34143/jtr.2015.22.4.57
- [8] S. C. Lee. (2006). Psychological effects on elderly driver's traffic accidents. *Korean Psychological Journal of Culture and Social Issues*. 12(5). 149-167.
- [9] J. M. Jang, J. S. Choi & T. H. Gim. (2017). Analyzing Driving Environment Effects on Severity of Elderly Driver's Traffic Accidents. *Journal of Transport Research*. 24(1). 79-94. DOI : 10.34143/jtr.2017.24.1.79
- [10] S. H. Lee, W. D. Jeung & Y. H. Woo. (2012). Comparative Analysis of Elderly's and Non-elderly's Human Traffic Accident Severity. *The Korea Institute Of Intelligent Transport Systems*. 11(6). 133-144.
- [11] S. G. Shin & M. S. Cho. (2010). A Study on Traffic Accident Prevention through Older Driver's Characteristics Analysis. *Journal of Korean Public Police and Security Studies*. 7(2). 157-185. DOI : 10.25023/kapsa.7.2.201008.157
- [12] S. J. Lim, J. T. Park, Y. I. Kim & T. H. Kim. (2012).

Analysis of Elderly Drivers` Accident Models Considering Operations and Physical Characteristics. Korean Society of Transportation. 30(6). 37-46.
DOI : 10.7470/jkst.2012.30.6.037

- [13] M. J. IEE & M. S. Lee. (2014). Elderly Driver's Perceived Driving Ability and Driving Behavior Associated with Traffic Accident Risk. Crisis and Emergency Management: Theory and Praxis. 10(12). 279-304.
- [14] L. Dominique & M. Fred. (2010). The statistical analysis of crash-frequency data: A review and assessment of methodological alternatives. Transportation Research Part A 44 291-305.
https://doi.org/10.1016/j.tra.2010.02.001
- [15] T. S. Peter, L. M. Fred, L. Dominique & A. Q. Mohammed. (2011). The statistical analysis of highway crash-injury severities: A review and assessment of methodological alternatives. Accident Analysis and Prevention. 43(6). 1666-1676.
https://doi.org/10.1016/j.aap.2011.03.025
- [16] Y. O. Kang, S. R. Son & N. H. Cho. (2017) Analysis of Traffic Accidents Injury Severity in Seoul using Decision Trees and Spatiotemporal Data Visualization. Korea Land and Geospatial InformatiX Corporation. 47(2). 233-254
https://doi.org/10.22640/lxsiri.2017.47.2.223
- [17] S. B. LEE, D. H. HAN & Y. I. LEE. (2015). Development of Freeway Traffic Incident Clearance Time Prediction Model by Accident Level. Journal of Korean Society of Transportation. 33(5). 497-507
DOI : 10.7470/jkst.2015.33.5.497
- [18] G. Chen, Z. Zhang, R. Qian, R. A. Tarefder, and Z. Tian. (2016). Investigating Driver Injury Severity Patterns in Rollover Crashes Using Support Vector Machine Models. Accident Analysis and Prevention. 90. 128-139.
https://doi.org/10.1016/j.aap.2016.02.011
- [19] M. Rezapour, A. Mehrara Molan, & K. Ksaibati. (2020). Analyzing injury severity of motorcycle at-fault crashes using machine learning techniques, decision tree and logistic regression models. International Journal of Transportation Science and Technology, 9(2), 89-99.
https://doi.org/10.1016/j.ijtst.2019.10.002
- [20] R. E. Mamlook et al. (2020). Utilizing Machine Learning Models to Predict the Car Crash Injury Severity among Elderly Drivers. IEEE International Conference on Electro Information Technology. July. 105-111.
DOI : 10.1109/EIT48999.2020.9208259
- [21] S. Alkheder, M. Taamneh, & S. Taamneh. (2017). Severity Prediction of Traffic Accident Using an Artificial Neural Network. Journal of Forecasting, 36(1), 100-108.
https://doi.org/10.1002/for.2425
- [22] J. H. Rho. (2012). Transportation planning : Travel demand theory and modeling
- [23] Zhang, J., Li, Z., Pu, Z., & Xu, C. (2018). Comparing prediction performance for crash injury severity among various machine learning and statistical

methods. IEEE Access, 6(c), 60079-60087.
https://doi.org/10.1109/ACCESS.2018.2874979

- [24] Mafi, S., AbdelRazig, Y., & Doczy, R. (2018). Machine Learning Methods to Analyze Injury Severity of Drivers from Different Age and Gender Groups. Transportation Research Record, 2672(38), 171-183.
https://doi.org/10.1177/0361198118794292
- [25] Breiman, L. (2001). Random forests. Machine Learning, 45, 5-32.
https://doi.org/10.1023/A:1010933404324

김 승 훈(Kim Seunghoon)

[정회원]



- 2008년 : 성균관 대학교 도시환경시스템 공학과 (학사)
- 2012년 : 한양대학교 도시 계획·개발 경영학과 석사
- 2020년 : 오하이오주립대학교 도시·지역계획학과 박사
- 관심분야 : 지속 가능한 개발, 사회 정의, 교통 사고

· E-Mail : gaeguri10@gmail.com

임 영 빈(Lym Youngbin)

[정회원]



- 2007년 : 서강대학교 수학과/경영학과 (학사)
- 2009년 : 동경대학교 도시공학과 석사
- 2020년 : 오하이오주립대학교 도시·지역계획학과 박사
- 2021년 1월 ~ 현재 : 한국과학기술원 기술경영학부 혁신전략연구센터 선임

연구원

- 관심분야 : 도시해석, 베이지언통계, 시공간분석, 교통사고
- E-Mail : youngbin.lym@gmail.com

김 기 정(Kim Ki-Jung)

[정회원]



- 2009년 : 충남대학교 메카트로닉스공과 (학사)
- 2011년 : 충남대학교 메카트로닉스공과 석사
- 2014년 : 충남대학교 메카트로닉스공과 박사
- 2018년 3월 ~ 현재 : 두원공과대학교

스마트자동차과 교수

- 관심분야 : 동역학, 의공학, 안전공학
- E-Mail : kimkj@doowon.ac.kr