

인공지능을 이용한 급성 뇌졸중 환자의 재원일수 예측모형 개발

최병관¹, 함승우², 김축환³, 서정숙⁴, 박명화⁵, 강성홍^{6*}

¹부산대학교 의과대학 신경외과, ²한국원자력의학원, ³순천향대학교 천안병원,

⁴연세의료원 세브란스병원, ⁵대한의무기록협회, ⁶인제대학교 보건행정학과

Development of Predictive Model for Length of Stay(LOS) in Acute Stroke Patients using Artificial Intelligence

Byung Kwan Choi¹, Seung Woo Ham², Chok Hwan Kim³, Jung Sook Seo⁴,
Myung Hwa Park⁵, Sung-Hong Kang^{6*}

¹Dept. of Neurosurgery, School of Medicine, Pusan National University

²Korea Institute of Radiological & Medical Sciences

³Soonchunhyang University Cheonan Hospital

⁴Severance Hospital, Yonsei University Health System

⁵Korean Medical Record Association

⁶Dept. of Health Policy & Management, InJe University

요 약 병원 재원일수의 효율적 관리는 병원의 수익과 환자의 진료비 절감을 위해 매우 중요한 요소이다. 이러한 재원일수의 효율적 관리를 위해서는 병원들이 재원일수에 대해서 벤치마킹을 할 수 있도록 지원이 필요하고 재원일수 절감의 구체적인 방향을 제시해 줄 수 있는 재원일수 예측모형의 개발이 필요하다. 본 연구에서는 2013년과 2014년도 퇴원손상환자 자료 중 급성뇌졸중 환자를 추출하여 분석용 자료를 만들고 인공지능을 이용하여 급성뇌졸중 환자의 재원일수 예측모형을 개발하였다. 분석용 자료는 훈련용 60%, 평가용 40%로 분류하였다. 모형개발은 전통적 통계기법인 다중회귀분석기법과 인공지능기법인 대화식 의사결정나무기법, 신경망 기법, 그리고 이들을 모두 통합한 앙상블기법을 이용하였다. 모형평가는 Root ASE(Absolute error) 지표를 이용하였는데, 다중회귀분석은 23.7, 대화식결정나무 23.7, 신경망 분석은 22.7, 앙상블은 22.7로 나타났고 이를 통하여 재원일수 예측모형 개발에 인공지능기법의 유용성이 입증되었다. 앞으로 재원일수 예측 모형개발에 인공지능 기법을 보다 효율적으로 활용할 수 있는 방안에 대해서 계속적인 연구가 이루어 질 필요가 있다.

주제어 : 재원일수 예측모형, 인공지능, 급성뇌졸중, 신경망, 대화식의사결정나무

Abstract The efficient management of the Length of Stay(LOS) is important in hospital. It is important to reduce medical cost for patients and increase profitability for hospitals. In order to efficiently manage LOS, it is necessary to develop an artificial intelligence-based prediction model that supports hospitals in benchmarking and reduction ways of LOS. In order to develop a predictive model of LOS for acute stroke patients, acute stroke patients were extracted from 2013 and 2014 discharge injury patient data. The data for analysis was classified as 60% for training and 40% for evaluation. In the model development, we used traditional regression technique such as multiple regression analysis method, artificial intelligence technique such as interactive decision tree, neural network technique, and ensemble technique which integrate all. Model evaluation used Root ASE (Absolute error) index. They were 23.7 by multiple regression, 23.7 by interactive decision tree, 22.7 by neural network and 22.7 by ensemble technique. As a result of model evaluation, neural network technique which is artificial intelligence technique was found to be superior. Through this, the utility of artificial intelligence has been proved in the development of the prediction LOS model. In the future, it is necessary to continue research on how to utilize artificial intelligence techniques more effectively in the development of LOS prediction model.

Key Words : LOS prediction model, Artificial intelligence, Acute stroke, Neural network, Interactive decision tree

*This work was supported by the 2016 Inje University research grant.

*Corresponding Author : Sung-Hong Kang(hcmkang@inje.ac.kr)

Received November 22, 2017

Revised December 28, 2017

Accepted January 20, 2018

Published January 28, 2018

1. 서론

미국에서 의료분야의 인공지능의 시장규모는 2014년에 6천9백억원이던 것이 2012년에는 7조6천억원으로 연간 40%씩 증가할 것으로 전망되고 있다. 특히, 2021년부터 2026년 사이의 5년간에는 시장규모가 10배 증가하여 2026년에는 170조원 정도로 추정하고 있다. 2026년에 의료분야에서 인공지능의 영역별 시장규모는 로봇보조수술 46조원, 가상간호서비스지원 23조원, 업무프로세스 개선 21조원, 건강보험심사 20조원 등의 순으로 예측되었다[1].

재원일수는 의료기관에서 적극적으로 관리하고 국가 또한 세심하게 챙겨보는 항목 중의 하나이다. 첫째, 재원기간을 줄수록 의료기관은 수익성이 향상될 수 있다. 둘째, 환자는 입원기간이 짧을수록 입원비가 절감되는 효과를 얻을 수 있다. 셋째, 국가 차원에서는 건강보험 재정을 건전화 할 수 있으며 제한적일 수밖에 없는 의료자원을 효율적으로 활용할 수 있게 된다.

재원일수를 관리하는데 있어서 의료기관간에 재원일수를 비교하여 벤치마킹할 수 있도록 해주는 재원일수 예측모형의 개발이 매우 중요하다. 왜냐하면 동일 질환군 환자일지라도 환자의 중증도와 의료기관의 특성 등이 다름에 따라 이를 보정할 수 있는 재원일수 예측모형을 개발하여 예측된 재원일수와 병원의 실제 재원일수를 비교할 수 있을 때만 제대로 된 벤치마킹을 할 수 있기 때문이다.

이러한 필요성에 부응하여 통계기법을 이용하여 재원일수를 예측하는 다양한 연구가 이루어져 왔다. Gorden은 십이장격양환자의 재원일수 예측모형을 통계적인 기법을 이용하여서 개발하였고, Chien-Lin Lin은 통계적인 모형에 근거하여 뇌출혈 및 뇌경색환자에 대한 재원일수 예측 모형을 개발하였다[2,3]. 기존의 통계기법보다 예측을 보다 잘 할 수 있는 인공지능 기법이 대두됨에 따라 인공지능 기법을 활용한 재원일수 예측모형의 개발이 필요하게 되었다. 인공지능이라는 것은 인간의 학습능력, 추론능력, 지각능력, 자연언어의 이해능력 등을 컴퓨터 프로그램으로 실현한 기술을 말한다. 인공지능을 구현하는 주요방법으로는 머신러닝이 대표적이다. 머신러닝은 인공지능의 한 분야로, 컴퓨터가 학습할 수 있도록 하는 알고리즘과 기술을 개발하는 분야를 말한다. 머신러닝의 기법으로는 일반화선형모형, 의사결정나무, 신

경망, 딥러닝, 클러스터링 등이 있다. 최근에 이러한 인공지능 기법을 이용하여 재원일수를 예측하는 연구가 본격적으로 진행이 되고 있다. 외국에서는 Luigi Lella가 신경망 기법을 이용하여 재원일수 예측모형을 개발하였고, Sean Bames는 Supervised Machine Learning 기법을 이용하여 재원일수 예측 모형을 개발하였다[4,5]. 국내에서는 홍성욱이 목의 손상환자에 대해서 중증도 보정 재원일수 예측모형을 의사결정나무 기법을 이용하여 개발하였고, 정석훈은 신경망기법을 이용하여 재원일수 예측모형을 개발하였다[6,7]. 이러한 연구를 통하여 기존의 통계기법보다는 인공지능 기법을 이용하여 재원일수를 예측하는 것이 보다 우수한 모델을 개발할 수 있는 것으로 나타났다. 따라서 이제는 인공지능을 이용하여 재원일수의 예측모형의 우수성을 입증하는 연구보다는 인공지능의 다양한 기법을 보다 효율적으로 활용하여 실제 의료기관에서 재원일수를 절감할 수 있는 구체적인 방향을 제시할 수 있는 연구가 필요하다. 본 연구에서는 인공지능을 이용하여 재원일수 예측모형을 개발하여 재원일수에 대한 체계적인 벤치마킹과 이를 기반으로 구체적인 재원일수 절감을 위한 노력을 유도할 수 있는 데이터 분석 방안에 대해서 연구를 하고자 한다.

급성 뇌졸중은 뇌혈관 질환 중 가장 흔히 발생하는 질환으로 노인 인구에서의 발생률이 높기 때문에 평균 수명 연장으로 인한 인구 노령화 등 고령화 사회로 접어들어 우리나라에서도 발생빈도가 지속적으로 증가하고 있으며 의료비 부담을 가중시키는 질환이다. 이에 국가에서는 의료기관에서 제공하는 급성 뇌졸중 의료서비스의 질 향상 및 의료비 감소를 위해 2006년부터 급성 뇌졸중에 대한 적정성평가 사업을 실시하고 있으며, 2007년부터는 급성 뇌졸중 적정성평가에 대한 평가결과 공개하고 있다. 2011년부터는 급성 뇌졸중 평가 가감사업을 진행하고 있다. 국가에서 실시하고 있는 급성 뇌졸중 의료서비스의 질 평가지표에 건당 입원일수가 있다. 이 중 건당 입원일수 즉, 급성 뇌졸중의 평균 재원일수는 급성 뇌졸중의 진료결과와 의료서비스 질적 변이를 간접적으로 진단하는 가장 유용한 도구이며, 급성 뇌졸중 환자들을 위한 한정된 병원자원의 효율적 활용이란 측면에서 병원 경영을 위해서도 반드시 관리되어야 할 지표이다. 따라서 의료기관에서 급성 뇌졸중 환자의 재원일수 관리에 관심을 가지고 있음에 따라 급성 뇌졸중 환자를 대상으로 재원일수 예측모형을 개발할 필요성이 있다. 강성홍과 김영의

는 급성뇌졸중 환자의 중증도 보정 재원일수 예측모형을 개발하여 발표하였다[8,9]. 그러나 이 모형은 재원일수의 중증도 보정을 목적으로 개발된 모형임에 따라 벤치마킹이나 실제적인 재원일수 절감을 위한 개선방안의 도출에는 제한점이 있다. 본 연구에서는 이러한 제한점을 극복하기 위해서 인공지능 기법을 이용하여 벤치마킹 목적의 급성뇌졸중의 재원일수 예측 모형을 개발하고, 이를 기반으로 인공지능의 다양한 기법을 효율적으로 활용하는 방안을 제시하고자 한다.

2. 연구방법

2.1 연구방법

2.1.1 자료수집

본 연구를 위해 질병관리본부로부터 2013년부터 2014년까지 퇴원손상 심층조사 자료 450,009건을 수집하였다. 퇴원손상 심층조사는 질병관리본부에서 미국의 퇴원환자조사 방법론을 근거로 하여 2004년에 구축하였으며, 전체 입원환자를 대상으로 조사한 전국단위의 행정자료이다. 퇴원손상 심층조사의 조사항목에는 성, 연령, 보험유형 등 환자의 인적사항, 진단, 부진단, 입원경로, 재원일수 등 환자의 주요 진료내역 정보를 포함하고 있다[8].

2.1.2 분석대상자 추출

수집된 퇴원손상 심층조사 자료 중 건강보험심사평가원의 급성 뇌졸중 평가대상 질환군 정의에 따라 본 연구에서도 퇴원손상 심층조사 자료의 진단 자료를 바탕으로 진단 코드 I60, I61, I62, I63에 해당하는 급성 뇌졸중 환자 자료 7,409건을 추출하였으며, 선행연구의 분석대상자 제외조건 및 전문가의 자문에 따라 0~19세 및 93세 이상인 자료, 진료비지불방법이 무료, 공상, 기타, 불명인 자료, 입원경로가 기타, 불명인 자료, 재원일수가 366일 이상인 자료, 퇴원형태가 기타, 불명인 자료, 치료결과가 기타 및 불명인 자료를 삭제한 7,331건을 급성 뇌졸중 환자의 재원일수 예측 모형개발을 위한 모형개발을 위한 분석대상자로 추출하였다[10].

2.2 변수정의

본 연구에서는 선행연구 방법 및 전문가의 자문에 따라 급성 뇌졸중 환자의 성, 연령, 진료비 지불방법, 입원

경로, 사망 유무, 수술 유무, Charlson comorbidity index 등을 급성 뇌졸중 환자의 재원일수 예측 모형 개발을 위한 변수로 사용하였다. Charlson comorbidity index는 행정자료에서 가장 널리 사용되고 있는 동반질환 측정도구로서 의무기록조사를 통하여 정의된 19개의 질환에 대하여 1~6점까지 일정한 가중치를 부여한 뒤 이 가중치의 합을 보정하는 방법이다[10]. 이 밖의 변수에 대한 구체적인 정의는 <Table 1>과 같다.

<Table 1> Definition of Variables

Variables	Definitions
Sex	Either of the two categories (male or female) into which most organisms are divided
Age	Length of time that a person has lived or a thing has existed.
Payment compensation type	Pay compensation type of medical care
LOS	Length of Stay in hospital
Admission route	When a patient is hospitalized, type of whether the patient passed through the outpatient department or passed the emergency room
Principal Diagnosis Code	Diagnostic code leading to hospitalization
Existence of secondary diagnosis	Presence or absence of secondary diagnosis
Existence of Surgery	Presence or absence of Surgery
Discharge Type	Place to go when patient is discharged
Treatment outcome	Health status of patient at discharge
Hospital location	The metropolitan region where the hospital is located
Bed size	Number of beds operated by the hospital
Charlson comorbidity index	A method of categorizing comorbidities of patients based on the International Classification of Diseases (ICD) diagnosis codes found in administrative data, such as hospital abstracts data.

2.3 분석방법

2.3.1 통계분석

분석대상자의 일반적 특성, 제 특성에 따른 급성뇌졸중환자의 재원일수를 살펴보기 위해 t검정과 분산분석을 실시하였다. 통계분석은 IBM SPSS statistics 20을 이용하였다.

2.3.2 모형개발

급성 뇌졸중 환자의 재원일수 예측모형을 개발하기

위하여 일반적인 통계기법인 다중회귀분석과 인공지능 기법인 대화식의사결정나무, 신경망 기법과 이들을 모두 통합한 앙상블 기법을 이용하여 모형을 개발하였다. 다중회귀분석은 변수들 간의 인과 관계를 파악하기 위한 대표적인 기법으로 모형의 전체적인 주요 요인을 살펴보는 데 장점이 있으나 엄격한 통계적인 가정을 요구하고 인공지능기법에 비해서는 예측력이 떨어지는 단점이 있다[11]. 의사결정나무는 특정한 분류기준에 따라 목표변수와 가장 관련성이 높은 변수를 선정한 후 의사결정규칙을 몇 개의 소집단으로 분류하여 나무구조로 표현하는 것으로 요인의 규명, 분류, 예측에 유용하다. 또한, 의사결정나무는 독립변수간의 관계를 도식화 하여 보여주기 때문에 연구자가 분석결과를 쉽게 설명할 수 있는 장점이 있다[12]. 신경망기법은 인간의 뇌세포들이 신경망을 통하여 주변의 다른 뇌세포들과 정보를 주고받으면서 계산을 하거나 의사결정을 내리는 과정을 모방하고 있는 기법으로 모형의 예측력이 높다는 장점이 있다. 그러나 모형의 주요 요인을 알 수 없고, 오버피팅이 되어서 모형을 만드는 데이터에서는 설명력이 높으나 다른 데이터를 이를 적용할 시에는 잘 맞지 않는 단점이 있다[13]. 앙상블모형은 여러 가지 기법에서 예측한 값의 평균을 구해서 이를 이용하여 예측하는 기법으로서 개개 기법의 단점을 보완해 줄 수 있다는 장점이 있다[14].

이와 같이 통계 및 인공지능의 각 기법은 각기 장단점이 있음에 따라 특정 기법에 의존하기 보다는 각 기법의 장점을 종합적으로 활용하는 것이 필요하다. 데이터 분석의 유형은 크게 기술적 분석(descriptive analysis), 예측적 분석(predictive analysis), 대안적 분석(prescriptive analysis)이 있다. 기술적 분석은 현황 및 관련요인을 파악하는 분석이고, 예측적 분석은 기존데이터를 기반으로 하여 예측을 하는 분석이고, 대안적 분석은 문제를 해결하기 어떤 방안을 쓰면 될지를 파악하는데 도움이 되는 기법이다[19]. 우리가 급성뇌졸중 환자의 재원일수 예측 모형을 개발하는 목적은 벤치마킹을 통하여 실제적인 재원일수 관리가 이루어지도록하기 위해서이다. 이를 위해서는 기술적 분석, 예측적 분석, 대안적 분석이 모두 필요하다. 본 연구에서는 기술적 분석에는 다중회귀분석기법, 예측적 분석에는 신경망기법, 대안적 분석에는 대화식의사결정나무 기법이 적합하다고 판단하고, 이들 모두를 이용하여 모형을 개발하였다. 또한 예측적 분석에는 신경망기법만을 쓰는 것 보다는 3가지 기법에서 예측한 평

균값을 사용하는 것이 합리적이라 판단하여 앙상블 기법을 사용하는 것이 합리적이라 판단하여 4가지 기법을 모두 활용하여서 분석을 하였다.

모형개발에 사용된 다중회귀분석은 단계적 선택방법(stepwise) 이용하여 급성 뇌졸중 환자의 재원일수에 유의한 영향을 미치는 변수만을 추출하고자 하였고, 대화식의사결정나무분석은 분산의 감소량을 최대화하는 기준의 최적분리에 의해 지식마디가 형성되는 Variance reduction방법을 이용하여 모형을 개발하였으며, 신경망 분석은 Profit/Loss방법을 이용하였다. 앙상블모형은 각각의 다중회귀분석, 대화식의사결정나무, 신경망 기법의 예측치를 평균으로 산출하는 앙상블 모형을 사용하였다.

본 연구에서, 다중회귀분석 및 인공지능분석은 SAS Enterprise Miner Workstation 13.1을 이용하였다.

2.3.3 모형평가

급성 뇌졸중 환자의 재원일수 예측 모형의 성능평가를 위해서 전체 데이터 중 60%는 모형개발용 분석자료(Train Data)로 사용하였고 나머지 40%에는 모형의 평가자료(Validation data)로 사용하여 모형의 타당도 평가를 실시하였다. 개발된 모형의 타당도 평가는 Root ASE(Absolute Squared Error)값을 이용하였다.

3. 연구결과

3.1 분석대상자의 특성

3.1.1 분석대상자의 일반적 특성

본 연구의 분석대상자는 7,331명이였다. 분석대상자의 일반적 특성은 성별로는 남자 54.9%, 여자 45.1%였다. 연령별로는 70-79세가 31.8%, 60-69세가 21.6%로 나타났다. 지불보상유형별로는 건강보험이 91.5%, 의료급여가 7.9%였다. 입원경로별로는 응급실 76.1%, 외래 23.9%였다. 병상규모별로는 500-599병상이 56.9%, 100-299병상이 17.8%였다.

<Table 2> General characteristics of acute stroke patients

Variables		N	%
Sex	Male	4,025	54.9
	Female	3,306	45.1
Age	-49	892	12.2
	50-59	1,367	18.6

	60-69	1,584	21.6
	70-79	2,331	31.8
	80+	1,157	15.8
Payment compensation type	Health Insurance	6,709	91.5
	Medicaid	582	7.9
	Other	40	0.5
Admission route	Emergency room	5,579	76.1
	Ambulatory	1,752	23.9
Existence of Surgery	No	6,305	86.0
	Yes	1,026	14.0
Existence of secondary diagnosis	No	1,525	20.8
	Yes	5,806	79.2
Discharge Type	Home	5,593	76.3
	Transfer	1,206	16.5
	Death	516	7.0
	Other	16	0.2
Treatment outcome	Improvement	6,387	87.1
	Not Improvement	257	3.5
	Diagnosis only	147	2.0
	Hopeless	24	0.3
	Death	516	7.0
Bed size	100-299	1,306	17.8
	300-499	863	11.8
	500-999	4,168	56.9
	1000+	994	13.6
	Total	7,331	100.0

3.1.2 분석대상자의 주진단 및 Charlson 지수

분석대상자의 주진단은 뇌경색 71.7, 뇌내출혈 15.4% 등의 순으로 나타났다. Charlson comorbidity index는 0 점 49.8%, 1점 28.0%, 2점 12.5%, 3점 6.0%, 4점 이상 3.7%로 점수가 낮은 집단이 많은 것으로 나타났다.

<Table 3> Distribution of Diseases & Charson Index

		N	%
Principal diagnosis	Subarachnoid haemorrhage	661	9.0
	Intracerebral haemorrhage	1,130	15.4
	Other nontraumatic intracranial haemorrhage	284	3.9
	Cerebral infarction	5,256	71.7
Charlson comorbidity index	0	3,650	49.8
	1	2,054	28.0
	2	915	12.5
	3	443	6.0
	4+	269	3.7
Total		7,331	100.0

3.1.3 분석대상자의 병원소재지

분석대상자들이 이용한 병원의 소재지는 서울 21.3%, 경기 15.8%, 대구 7.4%, 광주 6.0% 등의 순으로 나타나서 서울지역 의료기관을 이용한 자가 가장 많은 것으로 나타났다.

<Table 4> Location distribution of utilization hospital

Hospital location	N	%
Seoul	1,561	21.3
Busan	419	5.7
Daegu	543	7.4
Incheon	320	4.4
Gwangju	438	6.0
Daejeon	238	3.2
Ulsan	164	2.2
Gyeonggi	1,155	15.8
Gangwon	400	5.5
Chungbuk	267	3.6
Chungnam	266	3.6
Jeonbuk	416	5.7
Jeonnam	156	2.1
Gyeongbuk	418	5.7
Gyeongnam	429	5.9
Jeju	141	1.9
Total	7,331	100.0

3.2 제 특성에 따른 평균재원일수

3.2.1 일반적인 특성에 따른 평균재원일수

성별 평균재원일수는 남자가 16.9일로 여자 18.6일에 비해 높았다. 연령별로는 49세 이하가 19.8일, 50-59세 19.6일, 60-69세 17일로 연령이 증가할수록 평균재원일수는 낮았다. 지불보상유형별로는 건강보험 17.2일, 의료급여 22.3일, 기타 28.1일로 나타났다. 입원경로별로는 응급실경유가 18.9일로 외래 경유 13.6일에 비해 높았다. 수술 유무별로는 수술한 환자의 평균재원일수는 35.3일, 수술을 하지 않은 환자는 14.8일로 나타났다. 부 진단 유무별로는 부 진단이 있는 환자의 평균재원일수는 19.2일로 부 진단이 없는 환자의 11.8일에 비해 높았다. 퇴원형태별로는 사망인 경우는 29.8일, 전원은 25.6일, 귀가는 16.1일로 나타났다. 치료결과별로는 호전이 18.2일, 사망이 15.7일로 치료결과에 따라 평균재원일수가 차이가 있었다. 병상규모별로는 300-499병상이 20.8일, 100병상이 14.6일로 나타났다.

<Table 5> Difference of ALOS according to general characteristics

Variables		N	ALOS	p
Sex	Male	4,025	16.9	0.00
	Female	3,306	18.6	
Age	<49	892	19.8	0.00
	50-59	1,367	19.6	
	60-69	1,584	17.0	
	70-79	2,331	17.4	
	80+	1,157	15.2	
Payment	Health care	6,709	17.2	0.00

compensation type	Medicaid	582	22.3	0.00
	Other	40	28.1	
Admission route	Emergency room	5,579	18.9	0.00
	Ambulatory	1,752	13.6	
Existence of Surgery	No	6,305	14.8	0.00
	Yes	1,026	35.3	
Existence of secondary diagnosis	No	1,525	11.8	0.00
	Yes	5,806	19.2	
Discharge Type	Home	5,593	16.1	0.00
	Transfer	1,206	25.6	
	Death	516	29.8	
	Other	16	15.7	
Treatment outcome	Improvement	6,387	18.2	0.00
	Not Improvement	257	14.2	
	Diagnosis only	147	7.0	
	Hopeless	24	9.0	
Bed size	Death	516	15.7	0.00
	100-299	1,306	19.1	
	300-499	863	20.8	
	500-999	4,168	17.3	
	1000+	994	14.6	
Total		7,331	17.7	

• ALOS(Average Length of Stay)

3.2.2 진단명에 따른 평균재원일수

주 진단별로는 뇌내출혈이 28.9일로 지주막하 출혈의 25.2일, 기타의 17.2일에 비해 높았다. Charlson comorbidity index별로는 4점 이상인 경우는 39.4일, 0점은 13.4일로 점수가 높을수록 평균재원일수가 높았다.

<Table 6> Difference of ALOS according to Principal diagnosis and Charlson comorbidity index

Variables	N	ALOS	p	
Principal diagnosis	Subarachnoid haemorrhage	661	25.2	0.00
	Intracerebral haemorrhage	1,130	28.9	
	Other nontraumatic intracranial haemorrhage	284	17.2	
	Cerebral infarction	5,256	14.3	
	0	3,650	13.4	
Charlson comorbidity index	1	2,054	15.9	0.00
	2	915	25.0	
	3	443	33.2	
	4+	269	39.4	
Total		7,331	17.7	

• ALOS(Average Length of Stay)

3.2.3 병원 소재지에 따른 평균재원일수 차이

병원소재지별 평균재원일수는 광주 14.5일, 인천 15.4일, 대구 16.6일로 짧은 반면에 제주 24.6일, 전남 23.2일 등으로 재원일수가 높았다.

<Table 7> Difference of LOS according to Hospital location

Hospital location	N	ALOS	p
Seoul	1,561	17.0	0.00
Busan	419	17.9	
Daegu	543	16.6	
Incheon	320	15.4	
Gwangju	438	14.5	
Daejeon	238	21.8	
Ulsan	164	23.5	
Gyeonggi	1,155	16.6	
Gangwon	400	20.3	
Chungbuk	267	17.2	
Chungnam	266	14.5	
Jeonbuk	416	17.3	
Jeonnam	156	23.2	
Gyeongbuk	418	18.7	
Gyeongnam	429	19.3	
Jeju	141	24.6	
Total		7,331	17.7

• ALOS(Average Length of Stay)

3.3 재원일수 예측모형 개발

3.3.1 모형개발 및 평가

급성 뇌졸중 환자의 재원일수 예측 모형을 다중회귀 분석, 대화식 의사결정나무, 신경망, 앙상블 기법을 이용하여 개발하였다. 모형개발은 훈련용 60%, 평가용 40%로 분류한 다음 훈련용 데이터로 모형을 개발하고, 평가용 데이터를 이용하여 모형을 평가하였다. 모형평가는 Root ASE지표를 이용하였다. 평가용 데이터에서 Root ASE는 신경망 기법이 22.7, 앙상블 모형이 22.7이 가장 낮은 것으로 나타났다. 즉, 신경망기법이나 앙상블기법이 예측력이 가장 우수한 것으로 나타났다.

<Table 8> Model assessment

	Root ASE (Test 40%)
Multiple Regression	23.7
Interactive Decision Tree	23.7
Neural Network	22.7
Ensemble	22.7

3.3.2 모형의 결과

3.3.2.1 다중회귀분석

급성 뇌졸중 환자의 재원일수 예측모형은 종속변수는 재원일수, 독립변수는 성, 연령, 지불보상유형, 입원경로, 수술유무, 부진단유무, 퇴원형태, 치료결과, 병상규모, 주진단, Charson comorbidity index, 병원소재지로 하여 단계별 선택방법에 따라서 모형을 개발하였다. 재원일수에 영향을 끼치는 유의한 변수는 성, 지불보상유형, 입원경로, 수술유무, 부진단유무, 퇴원형태, 치료결과, 병상규모, 주진단, Charson comorbidity index, 병원소재지로 나타났다. 모형의 설명력인 R²는 0.22로 나타났다.

주진단의 경우 뇌경색 환자에 비해서 지주막하 출혈, 뇌내출혈 환자인 경우 재원일수는 길고, 기타 비외상성 두 개내 출혈환자인 경우는 재원일수는 짧았다. 수술 및 부진단이 없는 환자일수록 재원일수는 짧았다. 치료결과는 사망을 기준으로 했을 경우 호전, 호전되지 않음, 진단만 환자는 재원일수가 길고, 가망 없으면 짧았다. 퇴원형태별로는 기타를 기준으로 했을 경우 귀가, 전원, 사망이면 재원일수는 짧았다. 병원소재별로는 제주를 기준으로 했을 경우 서울, 대구 등의 재원일수는 짧고, 부산, 대전 등의 재원일수는 길었다. 병상규모별로는 1,000병상을 기준으로 했을 경우 100-299병상, 300-499병상은 재원일수가 길고, 500-599병상은 짧은 것으로 나타났다. 지불보상 유형별로는 일반을 기준으로 했을 때 건강보험, 의료급여 1종은 재원일수가 짧고, 의료급여 2종, 산재보험, 자동차보험은 길었다. 성별로는 여자에 비해 남자가 짧은 것으로 나타났다.

3.3.2.2 대화식의사결정나무 분석결과

대화식 의사결정나무 분석에 따르면 급성뇌졸중 환자의 재원일수를 결정하는 가장 중요한 요인은 수술유무로 나타났다. 수술환자인 경우에는 Charlson comorbidity index 점수가 높을수록 재원일수가 길었다. 그 다음으로 중요한 변수는 주진단인 것으로 나타났다. 수술을 하지 않은 환자의 경우에도 재원일수를 결정하는 주요 요인은 Charlson comorbidity index, 주진단 유형인 것으로 나타났다. 그 하위그룹에서는 성, 병상규모 등 다양한 요인이 재원일수에 영향을 끼쳤다. 대화식 의사결정나무 분석을 통해서 재원일수의 차이의 요인을 특정집단별로 구체적으로 알 수 있었다.

<Table 9> Result of Multiple Regression

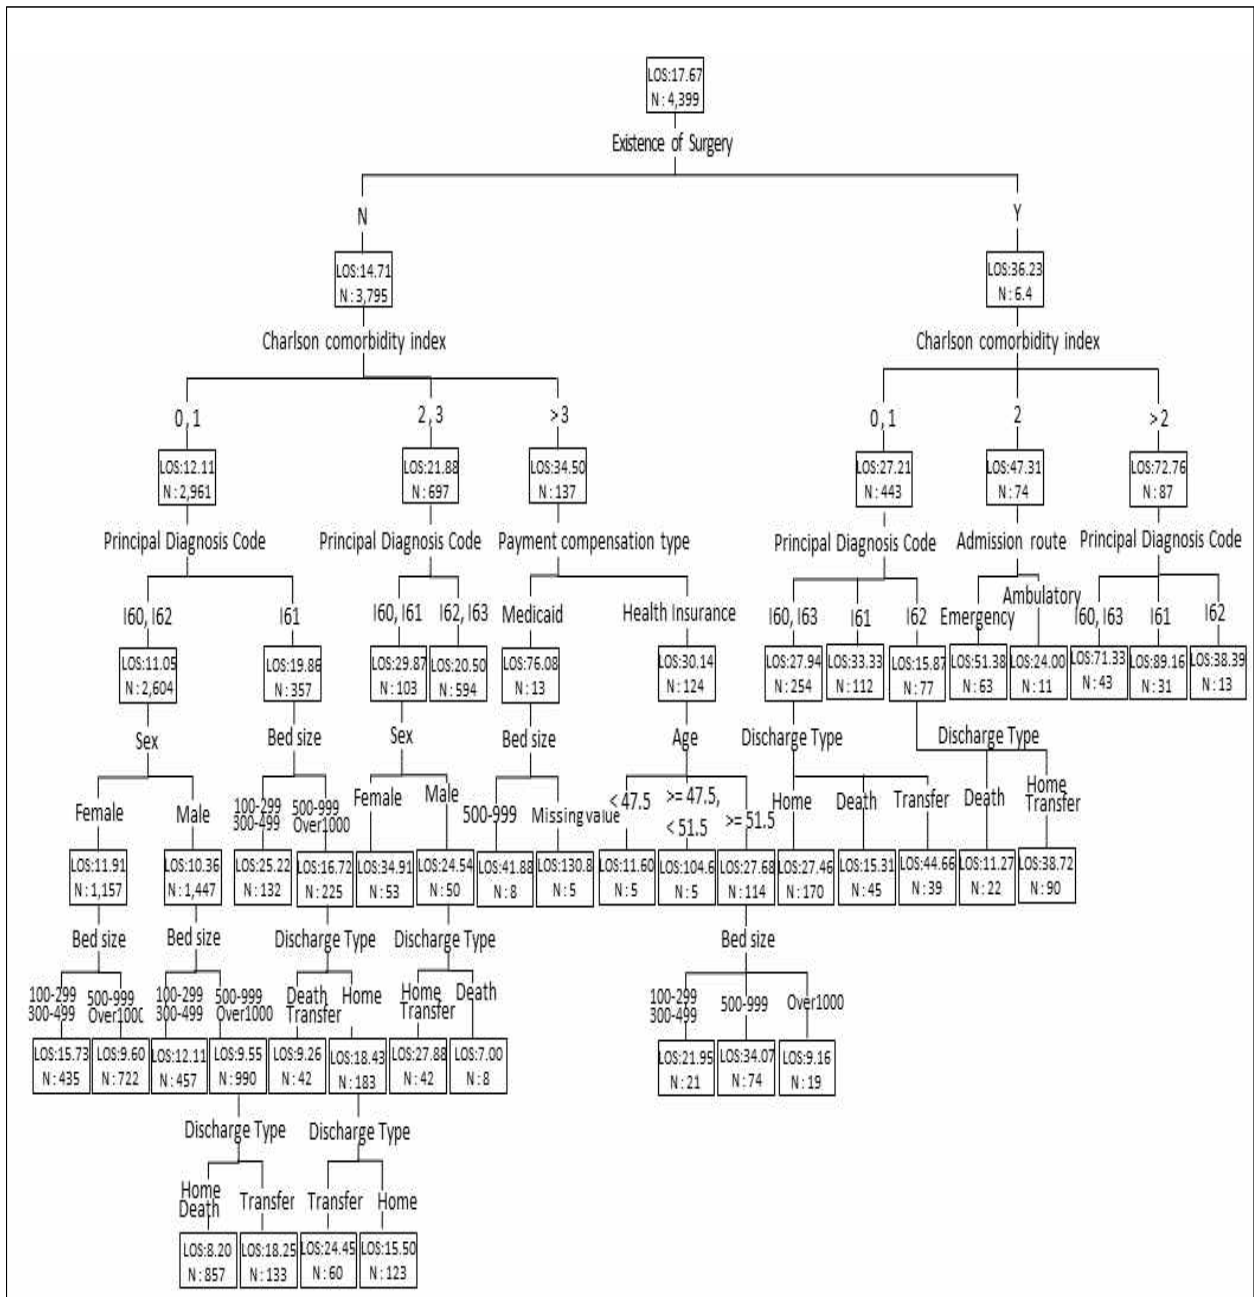
Variables	Value	B	P
Intercept		26.31	<.0001
Principal diagnosis	Subarachnoid haemorrhage	1.99	0.0604
	Intracerebral haemorrhage	7.80	<.0001
	Other nontraumatic intracranial haemorrhage	-8.67	<.0001
	Cerebral infarction		
Existence of Surgery	No	-10.47	<.0001
	Yes		
Existence of secondary diagnosis	No	-1.90	<.0001
	Yes		
Admission route	Emergency room	1.95	<.0001
	Ambulatory		
Charlson comorbidity index		4.43	<.0001
Treatment outcome	Improvement	17.10	0.0094
	Not Improvement	7.55	0.2642
	Diagnosis only	6.68	0.3299
	Hopeless Death	-6.09	0.4461
Discharge Type	Home	-11.02	0.1682
	Transfer	-4.21	0.6006
	Death	-5.84	0.5161
	Other	0.00	.
Hospital location	Seoul	-1.97	0.0204
	Busan	0.23	0.8738
	Daegu	-0.58	0.6465
	Incheon	-2.07	0.212
	Gwangju	-3.04	0.0387
	Daejeon	4.27	0.0145
	Ulsan	3.49	0.1054
	Gyeonggi	-1.80	0.051
	Gangwon	1.07	0.4596
	Chungbuk	-1.70	0.3342
	Chungnam	-4.97	0.0069
Jeonbuk	1.69	0.2417	
Jeonnam	2.98	0.1733	
Gyeongbuk	3.10	0.0287	
Gyeongnam	0.28	0.8401	
Bed size	Jeju		
	100-299	5.09	<.0001
	300-499	2.76	0.0015
	500-999	-2.93	<.0001
	1000+		
Payment compensation type	Health Insurance	-11.77	<.0001
	Medicaid Type 1	-9.72	0.0017
	Medicaid Type 2	0.38	0.9353
	Industrial accident insurance	42.88	<.0001
	Car insurance	1.02	0.9162
Sex	General		
	Male	-0.74	0.0327
	Female		

4. 고찰

최근에 각광 받고 있는 인공지능 기법을 급성뇌졸중 환자의 재원일수 예측모형 개발에 효율적으로 활용할 수 있는 방안을 모색하기 위해 본 연구를 수행하였다. 이를 위해 2013년부터 2014년까지의 퇴원손상환자자료 중 한국표준질병사인분류(Korean Standard Classification of Disease, KCD)의 중분류 기준으로 주진단이 I60, I61, I62, I63인 급성 뇌졸중 환자 7,331건의 자료를 수집하였

다. 수집된 전체 데이터에 대해서 기술통계, t검정, 분산 분석을 실시하였다. 재원일수 예측모형 개발 및 평가는 데이터를 훈련용 60%, 평가용 40%로 나누어서 분석을 하였다. 재원일수 예측 모형개발은 단계적 선택의 다중 회귀분석기법, 대화식 의사결정나무기법, 신경망기법, 앙상블기법을 이용하였다. 모형평가는 Root ASE라는 평가 지표를 이용해서 평가를 하였다.

모형평가 결과 Root ASE는 신경망 기법이 22.7, 앙상블 모형이 22.7이 가장 낮은 것으로 나타났다. 즉, 신경망



[Fig. 1] Result of Interactive Decision Tree

기법이나 앙상블기법이 예측력이 가장 우수한 것으로 나타났다. 이를 통하여 급성뇌졸중 환자의 재원일수의 예측적 목적의 분석기법으로는 신경망기법이나 앙상블기법이 가장 적합한 것으로 나타났다. 단계별 선택의 다중회귀분석결과에 따르면 재원일수에 영향을 끼치는 주요변수는 주진단, 수술유무, 부진단

<Table 10> Prediction rules of Severity-adjusted length of stay(LOS) for acute stroke patients by decision tree

ID	Prediction rules	Adjusted LOS
1	Sex Male and Bed size 500~999, 1000+ and Discharge type Death, Return home, transferred again and Charlson comorbidity index = 1 and Existence of Surgery NO and Principal Diagnosis I60, I62, I63	8.2
2	Sex Female and Bed size 500~999, 1000+ and Charlson comorbidity index=0,1 and Existence of Surgery NO and Principal Diagnosis I60, I62, I63	9.6
3	Charlson index = 2, 3 and Existence of Surgery NO and Principal Diagnosis I62, I63	20.5
4	Sex Male and Bed size 300~499, 100~299 and Charlson comorbidity index = 0, 1 and Existence of Surgery NO and Principal Diagnosis I60, I62, I63	12.1
5	Sex Female and Bed size 300~499, 100~299 and Charlson comorbidity index=1 and Existence of Surgery NO and Principal Diagnosis I60, I62, I63	15.7
6	Discharge type Home and Charlson comorbidity index = 0, 1 and Existence of Surgery YES and Principal Diagnosis I60, I63	27.5
7	Sex Male and Bed size 500~999, 1000+ and Discharge type transfer and Charlson comorbidity index = 0, 1 and Existence of Surgery NO and Principal Diagnosis I60, I62, I63	18.2
8	Bed size 300~499, 100~299 and Charlson comorbidity index = 0, 1 and Existence of Surgery NO and Principal Diagnosis I61	25.2
9	Bed size 500~999, 1000+ and Discharge type Home and Discharge condition Improvement and Charlson comorbidity index = 0, 1 and Existence of Surgery NO and Principal Diagnosis I61	15.5
10	Discharge type Transfer, Home and Charlson comorbidity index = 0, 1 and Existence of Surgery YES and Principal Diagnosis I61	38.7
11	Charlson index = 0, 1 and Existence of Surgery YES and Principal Diagnosis I62	15.9
12	Insurance Class Health care and Bed size 1000+ and Charlson comorbidity index = 0, 1, 2, 3 and Age >= 51.5 and Existence of Surgery NO	34.1
13	Charlson index = 2, 3 and Admission Route Emergency and Existence of Surgery Yes	51.4
14	Bed size 500~999, 1000+ and Discharge type Transer and Discharge condition Improvement and Charlson comorbidity index = 0, 1 and Existence of Surgery NO and Principal Diagnosis I61	24.5
15	Sex Female and Charlson comorbidity index = 2, 3 and Existence of Surgery NO and Principal Diagnosis I60, I61	34.9
16	Discharge type Death and Charlson comorbidity index = 0, 1 and Existence of Surgery YES and Principal Diagnosis I60, I63	15.3
17	Charlson comorbidity index = 0, 1, 2 and Existence of Surgery No and Principal Diagnosis I60, I63	71.3
18	Bed size 500~999, 1000+ and Discharge type Death, Transer and Charlson comorbidity index = 0, 1 and Existence of Surgery NO and Principal Diagnosis I61	9.3
19	Sex Male and Discharge type Transfer, Home and Charlson comorbidity index = 2, 3 and Existence of Surgery NO and Principal Diagnosis I60, I61	27.9
20	Discharge type Transfer and Charlson comorbidity index = 0, 1 and Existence of Surgery YES and Principal Diagnosis I60, I63	44.6
21	Charlson comorbidity index = 0, 1, 2 and Existence of Surgery No and Principal Diagnosis I61	89.2
22	Discharge type Death and Charlson comorbidity index = 0, 1 and Existence of Surgery YES and Principal Diagnosis I61	11.3
23	Payment compensation type Health care and Bed size 300~499, 100~299 and Charlson comorbidity index = 0, 1, 2, 3 and Age >= 51.5 and Existence of Surgery NO	22.0
24	Payment compensation type Health care and Bed size 500~999 and Charlson comorbidity index = 0, 1, 2, 3 and Age >= 51.5 and Existence of Surgery NO	9.2
25	Charlson comorbidity index = 0, 1, 2 and Existence of Surgery No and Principal Diagnosis I62	38.4
26	Charlson comorbidity index = 2 and Admission Route Ambulatory and Existence of Surgery Yes	24.0
27	Sex Male and Discharge type Death and Charlson comorbidity index = 2, 3 and Existence of Surgery NO and Principal Diagnosis I60, I61	7.0
28	Payment compensation type Medicaid and Bed size 500~999 and Charlson comorbidity index >= 4 and Existence of Surgery NO	41.9
29	Payment compensation type Medicaid and Bed size Missing and Charlson comorbidity index = 0, 1, 2, 3 and Existence of Surgery NO	130.8
30	Payment compensation type Health care and Charlson comorbidity index = 0, 1, 2, 3 and Age < 47.5 and Existence of Surgery NO	11.6
31	Payment compensation type Health care and Charlson comorbidity index = 0, 1, 2, 3 and Age < 51.5 and Age >= 47.5 and Existence of Surgery NO	104.6

유무, 입원경로 급성뇌졸중 환자의 재원일수에 영향을 끼치는 주요 요인을 알수 있었다. 그러나 이를 통하여 재원일수를 절감할 수 있는 구체적 방안의 도출은 용이하지 않았다. 즉, 기술적 분석 목적으로는 적합하나 대안적 분석기법으로는 제한점이 있었다.

대화식 의사결정나무 분석결과에 따르면 재원일수에 영향을 끼치는 주요 요인은 수술유무, Charlson comorbidity index, 주진단, 지불보상유형, 성, 연령, 병상 규모, 퇴원형태 등으로 나타났다. 특히, 이러한 요인의 영향력의 정도가 각 하위집단별로 다르게 나타났다. 예컨대, 수술환자인 경우에는 Charlson comorbidity index 점수가 높을수록 재원일수가 길었다. 그 다음으로 중요한 변수는 주진단인 것으로 나타났다. 수술을 하지 않은 환자의 경우에는 재원일수를 결정하는 주요 요인은 Charlson comorbidity index, 주진단 유형인 것으로 나타났다. 그 하위그룹에서는 성, 병상규모 등 다양한 요인이 재원일수에 영향을 끼쳤다[8,9]. 즉, 각 집단의 특성에 따라 재원일수를 절감할 수 있는 보다 구체적인 방안을 도출해 줄 수 있는 정보를 제공해 줌에 따라 대안적 분석기법으로는 대화식 의사결정나무가 적합하다는 것을 알 수 있었다[16].

우리가 재원일수 예측모형을 개발하는 이유는 단순히 예측력이 높은 모형만이 필요한 것이 아니라 재원일수에 영향을 끼치는 주요 요인을 알아보고 그리고 각각의 하위 그룹별 특성을 파악해서 구체적으로 재원일수를 절감할 수 있는 방안을 알아는 것도 필요하다. 즉, 기술적 분석, 예측적 분석, 대안적 분석이 모두 필요하다. 본 연구를 통하여 급성뇌졸중환자의 재원일수를 예측하는 모형을 다중회귀분석, 대화식 의사결정나무, 신경망분석, 앙상블 기법을 이용하여 개발하고 모형의 우수성은 Root ASE 지표를 이용하여 평가를 하였다. 분석결과 다중회귀분석은 23.7, 대화식의사결정나무는 23.7, 신경망분석은 22.7, 앙상블은 22.7로 나타났다. 즉, 신경망 기법이나 앙상블기법이 가장 좋은 것으로 나타났다. 재원일수에 영향을 끼치는 주요 요인을 살펴보는 기술적 분석으로는 다중회귀분석이 가장 적합한 것으로 나타났다. 구체적으로 급성뇌졸중 환자의 재원일수 절감의 구체적인 방안을 마련하는 데는 대화식의사결정기법이 좋은 것으로 나타났다. 기존의 통계기반의 분석기법, 인공지능의 각 기법들은 각기 고유의 장점이 있으므로 이의 장점을 잘 살려서 종합적으로 데이터 분석을 할 필요가 있다는 것을 본

연구를 통해서 파악하게 되었다.

5. 결론

급성뇌졸중 환자의 재원일수 예측모형을 통계분석기법인 다중회귀분석기법, 인공지능기법인 대화식 의사결정나무, 신경망 기법을 이용하여 개발하였다. 또한 개발된 모형의 성능을 평가하고 평가결과를 검토한 결과 각각의 기법들이 정보 활용의 측면에서는 각기 장점이 있었다. 이를 통해서 우리는 특정기법에 의존하는 분석보다는 분석목적에 맞추어서 거기에 가장 적합한 기법을 활용할 필요가 있다는 것을 알게 되었다. 이를 통하여 다음과 같은 것을 제안하고자 한다.

첫째, 재원일수 예측모형을 개발할 시에는 모형의 성능 못지않게 개발 모형의 활용성을 고려하여 분석할 것을 제안한다.

둘째, 재원일수 예측 시에 특정 모형에 의존하는 방식보다는 여러 가지 모형의 결과를 평균하여 예측하는 앙상블기법을 활용할 것을 제안 한다.

셋째, 재원일수에 영향을 끼치는 주요요인을 파악하는 것은 전통적인 통계기법인 다중회귀분석 기법 등을 활용하여 분석을 하여 전체적인 현황을 파악할 필요가 있다.

넷째, 대안적 분석 측면에서는 대화식의사결정나무 기법이 도움이 되므로 이를 효율적으로 활용할 필요가 있다.

다섯째, 데이터 분석을 종합적인 관점에서 실시하고 그리고 분석결과를 서비스와 연계할 수 있는 방안도 고려하여서 분석하는 것이 필요하다.

REFERENCES

- [1] Accenture, "ARTIFICIAL INTELLIGENCE : Healthcare's New Nervous System", Accenture, pp.1-3, 2017.
- [2] G. H. Robinson, L. E. Davis, R. P. Leifer, "Prediction of Hospital Length of Stay", Health Services RESEARCH, pp. 287-300, 1966.
- [3] C. L. Lin, P. H. Lin, L. W. Chou, S. J. Lan, N. H. Meng, S. F. Lo, H. D. Isaac, "Model-based Prediction of Length of Stay for Rehabilitating Stroke Patients", J Formos Med Assoc, Vol. 108, No. 8, pp. 653-662, 2009.
- [4] L. Lella, A. D. Giorgio, A. F. Dragoni, "Length of Stay

Prediction and Analysis through a Growing Neural Gas Model”, 4th International Workshop on Artificial Intelligence and Assistive Medicine, pp.11-20, 2015.

[5] S. Barnes, E. Hamrock, M. Toerper, S. Siddiqui, S. Levin, “Real-time prediction of inpatient length of stay for discharge prioritization”, J Am Med Inform Assoc, Vol.32, pp. e2-e10, 2016.

[6] S. O. Hong, Y. T. Kim, J. H. Park, S. H. Kang, “ The Variation of Factors of Severity-Adjusted Length of Stay(LOS) in Injury of Neck, Health and Social Welfare Review, Vol. 35, No. 2, pp.561-563, 2015.

[7] S. H. Chung, W. S. Han, Y. M. Suh, H. S. Rhee, “Length-of-Stay Prediction Model of Appendicitis using Artificial Neural Networks and Decision Tree”, Vol. 10, No. 6, pp. 1424-1432, 2009.

[8] S. H. Kang, H. S. Seok, W. J. Kim, The Variation of Factors of severity-adjusted length of stay(LOS) in acute stroke patients, The Society of Digital Policy & Management, Vol.11, No.6, pp. 221-233, 2013.

[9] Y. G. Kim, “ Risk-Adjusted Mortality Rate of Inpatients with Acute Strokes and the Length of their stay-Focused on Medical Institutions with 500 Beds or More-”, KOREA UNIVERSITY, pp.46-64, 2013.

[10] K. H. Kim, “Comparative Study on Three Algorithms of the ICD-10 Charlson Comorbidity Index with Myocardial Infarction Patients”, Journal of Preventive Medicine and Public Health, Vol. 43, No. 1, pp.42-49, 2010.

[11] J. H. Oh, S. W. Chung. “Multivariate Analysis for Clinicians”, Clinics in Shoulder and Elbow, Vol.6, No. 1, pp.63-72, 2013.

[12] K. Y. Hwang, E. S. Lee, G. W. Kim, S. O. Hong, J. S. Park, M. S. Kwak, Y. J. Lee, C. H. Lim, T. H. Park, J. H. Park, S. H. Kang, “Development of Healthcare Data Quality Control Algorithm using Interactive Decision Tree : Focusing on Hypertension in Diabetes Mellitus Patients”, The Korean Journal of Health Service Management, Vol. 10, No.3, pp.63-74, 2016.

[13] S. Walczak, R. J. Scorpio, W. E. Pofahl, “Predicting Hospital Length of Stay with Neural Networks“, Proceedings of the Eleventh International FLAIRS Conference, pp. 333-337, 1998.

[14] M. R. Poynton, B. M. Choi, Y. M. Kim, I. S. Park, G. J. Noh, S. O. Hong, Y. K. Boo, S. H. Kang, “Machine Learning Methods Applied to Pharmacokinetic Modelling of Remifentanyl in Healthy Volunteers: a multi-method Comparison”, The Journal of International Medical Research, Vol. 37, pp. 1680-1691, 2009.

[15] IBM, “Descriptive, predictive, prescriptive: Transforming

asset and facilities management with analytics”, IBM, pp. 3-4, 2013.

[16] M. Sappelli, M. H.T. de Boer, “A Vision on Prescriptive Analytics”, The Third International Conference on Big Data, Small Data, Linked Data and Open Data, pp. 45-50, 2017.

최 병 관(Choi, Byung Kwan)

[정회원]



- 1993년 2월 : 부산대학교 의과대학(의학사)
- 1996년 2월 : 부산대학교 의학대학원 신경외과(의학석사)
- 2004년 2월 : 부산대학교 의학대학원 신경외과(의학박사)

- 2013년 9월 ~ 현재 : 부산대학교 의과대학 신경외과학교수
- 관심분야 : 의공학, 인공지능, 의료정보학, 학제간융합연구
- E-Mail : spine@pusan.ac.kr

함 승 우(Ham, Seung Woo)

[정회원]



- 2000년 2월 : 단국대학교 행정대학원 보건학 석사
- 2006년 8월 : 성균관대학교 경영대학원 경영학 석사
- 2013년 8월 : 인제대학교 보건대학원 보건학 박사

- 1989년 4월 ~ 현재 : 한국원자력의학원 원자력병원의 무기록과
- 관심분야 : 의무기록, 의료정보, 데이터 마이닝, 스마트헬스케어
- E-Mail : sungwooham@nate.com

김 축 환(Kim, Chok Hwan)

[정회원]



- 2006년 8월 : 순천향대학교 산업정보대학원 의료공학과 의료정보학 전공 (공학석사)
- 2003년 6월 ~ 현재 : 순천향대학교 천안병원 근무
- 관심분야 : 의무기록, 의료데이터

분석, 기계학습

- E-Mail : kchkam@naver.com

서 정 숙(Seo, Jung Sook) [정회원]



- 1996년 2월 : 연세대학교 보건대학원 병원행정학과(보건학 석사)
- 1995년 2월 ~ 현재 : 연세의료원 세브란스병원 의무기록팀
- 2011년 2월 ~ 현재 : 연세의료원 세브란스병원 의무기록팀장

▪ 관심분야 : 의료정보, 의무기록, 빅데이터, 인공지능, 데이터마이닝

▪ E-Mail : skongju@yuhs.ac

박 명 화(Park, Myung Hwa) [정회원]



- 2004년 2월 : 인제대학교 보건관리학과(학사)
- 1992년 2월 ~ 현재 : 대한의무기록협회사무국
- 2014년 2월 ~ 현재 : 대한의무기록협회사무국 사무총장

▪ 관심분야 : 의료정보, 의무기록관리, 보건분류체계

▪ E-Mail : kmra@chol.com

강 성 홍(Kang, Sung Hong) [정회원]



- 1990년 2월 : 서울대학교 보건대학원 보건관리학과 (보건학석사)
- 1997년 2월 : 인제대학교 일반대학원 보건학과 (보건학박사)
- 1998년 3월 ~ 현재 : 인제대학교 보건행정학과 교수

▪ 관심분야 : 보건정보, 의무기록, 데이터마이닝, 건강증진

▪ E-Mail : hcmkang@hanmail.net