(12) 특허협력조약에 의하여 공개된 국제출원

(19) 세계지식재산권기구
국제사무국

(43) 국제공개일
2020 년 9 월 17 일 (17.09.2020)

WIPO | PCT

(10) 국제공개번호
WO 2020/184747 A1

(51) 국제특허분류:
F02P 5/15 (2006.01) *B60W 30/14* (2006.01)
F02D 41/04 (2006.01) *B60W 40/02* (2006.01)
B60W 10/06 (2006.01) *B60W 50/14* (2012.01)
B60W 30/18 (2006.01)

(21) 국제출원번호: PCT/KR2019/002792

(22) 국제출원일: 2019 년 3 월 11 일 (11.03.2019)

(25) 출원언어: 한국어

(26) 공개언어: 한국어

(71) 출원인: 엘지전자 주식회사 **(LG ELECTRONICS INC.)** [KR/KR]; 07336 서울시 영등포구 여의대로 128, Seoul (KR).

(72) 발명자: **채종훈 (CHAE, Jonghoon)**; 06772 서울시 서초구 양재대로11길 19 LG전자 특허센터, Seoul (KR).

(74) 대리인: **허용록 (HAW, Yong Noke)**; 06252 서울시 강남구 역삼로 114 현죽빌딩 6층, Seoul (KR).

(81) 지정국 (별도의 표시가 없는 한, 가능한 모든 종류의 국내 권리의 보호를 위하여): AE, AG, AL, AM, AO, AT, AU, AZ, BA, BB, BG, BH, BN, BR, BW, BY, BZ, CA, CH, CL, CN, CO, CR, CU, CZ, DE, DJ, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IR, IS, JO, JP, KE, KG, KH, KN, KP, KR, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, ME, MG, MK, MN, MW, MX, MY, MZ, NA, NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL, PT, QA, RO, RS, RU, RW, SA, SC, SD, SE, SG, SK, SL, SM, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, ZA, ZM, ZW.

(84) 지정국 (별도의 표시가 없는 한, 가능한 모든 종류의 역내 권리의 보호를 위하여): ARIPO (BW, GH, GM, KE, LR, LS, MW, MZ, NA, RW, SD, SL, ST, SZ, TZ, UG, ZM, ZW), 유라시아 (AM, AZ, BY, KG, KZ, RU, TJ, TM), 유

(54) Title: ARTIFICIAL INTELLIGENCE DEVICE AND METHOD FOR CONTROLLING AUTO-STOP SYSTEM

(54) 발명의 명칭: 오토 스탑 시스템을 제어하는 인공 지능 장치 및 그 방법

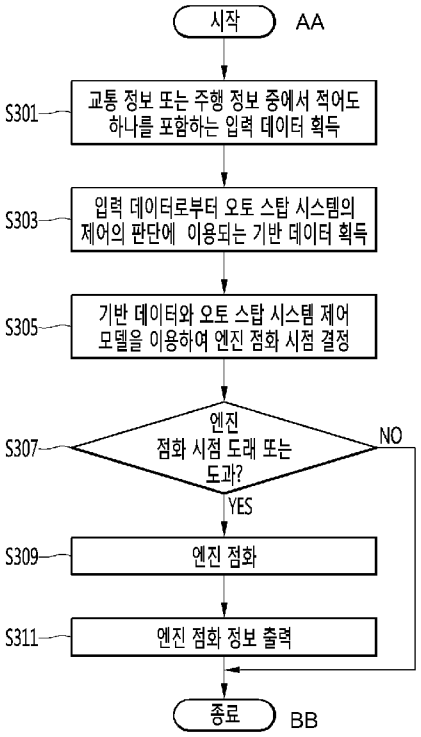

S301 ... Obtain input data including at least one of traffic information and driving information
S303 ... Obtain base data used to determine control of auto-stop system from input data
S305 ... Determine engine ignition time point by using base data and auto-stop system control model
S307 ... Is engine ignition time point arrived or elapsed?
S309 ... Ignite engine
S311 ... Output engine ignition information
AA ... Start
BB ... End

(57) Abstract: An embodiment of the present invention provides an artificial intelligence device for controlling an auto-stop function, the artificial intelligence device comprising: an input unit for receiving at least one of image information relating to the periphery of a vehicle, sound information relating to the periphery of the vehicle, brake information of the vehicle, and speed information of the vehicle; a storage unit for storing an auto-stop function control model; and a processor for obtaining input data related to at least one of traffic information and driving information through the input unit, obtaining base data used to determine the control of the auto-stop function from the input data, determining an engine ignition time point or whether to ignite an engine by using the base data and the auto-stop function control model, and automatically igniting the engine of the vehicle according to the determined engine ignition time

WO 2020/184747 A1

[다음 쪽 계속]

럽 (AL, AT, BE, BG, CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HR, HU, IE, IS, IT, LT, LU, LV, MC, MK, MT, NL, NO, PL, PT, RO, RS, SE, SI, SK, SM, TR), OAPI (BF, BJ, CF, CG, CI, CM, GA, GN, GQ, GW, KM, ML, MR, NE, SN, TD, TG).

공개:

— 국제조사보고서와 함께 (조약 제21조(3))

point or the determination on whether to ignite the engine, wherein the engine ignition time point refers to how long will it take when the engine is to be ignited after the input data is obtained or from the time point of the determination, and whether to ignite the engine refers to whether to ignite the engine at the time point when the input data is obtained or at the time point of the determination.

(57) 요약서: 본 발명의 실시 예는 오토 스탑 기능을 제어하는 인공 지능 장치에 있어서, 차량의 주변에 대한 영상 정보, 상기 차량의 주변에 대한 소리 정보, 상기 차량의 브레이크 정보 또는 상기 차량의 속도 정보 중에서 적어도 하나 이상을 수신하는 입력부; 오토 스탑 기능 제어 모델을 저장하는 저장부; 및 상기 입력부를 통하여 교통 정보 또는 주행 정보 중에서 적어도 하나 이상에 관련된 입력 데이터를 획득하고, 상기 입력 데이터로부터 상기 오토 스탑 기능의 제어의 판단에 이용되는 기반 데이터를 획득하고, 상기 기반 데이터와 상기 오토 스탑 기능 제어 모델을 이용하여 엔진 점화 시점 또는 엔진 점화 여부를 결정하고, 상기 결정된 엔진 점화 시점 또는 상기 결정된 엔진 점화 여부에 따라 자동으로 상기 차량의 엔진을 점화하는 프로세서를 포함하고, 상기 엔진 점화 시점은 상기 입력 데이터를 획득한 시점 또는 상기 결정 시점으로부터 얼마만큼 이후에 엔진을 점화할 것인지를 의미하고, 상기 엔진 점화 여부는 상기 입력 데이터를 획득한 시점 또는 상기 결정 시점에 엔진을 점화할 것인지 여부를 의미하는, 인공 지능 장치를 제공한다.

명세서

발명의 명칭: 오토 스탑 시스템을 제어하는 인공 지능 장치 및 그 방법

기술분야

[1] 본 발명은 오토 스탑 시스템을 제어하는 인공 지능 장치 및 그 방법에 관한 것이다. 구체적으로 교통 정보 또는 주행 정보 중에서 적어도 하나 이상에 기반하여 오토 스탑 시스템에 의하여 정지된 엔진을 점화하는 시점을 결정하고, 결정된 엔진 점화 시점에 따라 자동으로 엔진을 점화하는 인공 지능 장치 및 그 방법에 관한 것이다.

배경기술

[2] 오토 스탑 시스템 또는 ISG(Idle Stop & Go) 시스템은 차량이 정차한 경우에 엔진을 정지시키는 차량에 탑재된 시스템이다.

[3] 차량에 오토 스탑 시스템이 탑재된 경우에는 차량 정차 시 발생하는 엔진 공회전에 의한 연료 낭비와 공해를 줄이는 효과가 있다. 또한, 정차시 엔진 공회전 소리가 발생하지 않아 차량 외부 소리를 잘 들을 수 있어, 차량 외부의 다른 차량이나 사람 등과 발생할 수 있는 안전 사고를 방지하는데도 효과가 있다.

[4] 하지만, 기존의 오토 스탑 시스템은 정차 시에 엔진을 정지시키고, 사용자가 출발을 위하여 브레이크 페달에서 발을 떼거나 엔진 페달을 밟는 때에 다시 엔진을 점화시키게 되므로, 차량이 실제 정차 후 출발까지 일정 시간만큼 지연되는 문제점이 있다.

발명의 상세한 설명

기술적 과제

[5] 본 발명은 현재 차량의 주행 상황을 나타내는 교통 정보와 주행 정보를 기반으로 차량에 탑재된 오토 스탑 시스템에 의하여 정지된 엔진을 사용자의 별도의 조작이 없이도 자동으로 점화하는 인공 지능 장치 및 그 방법을 제공하고자 한다.

[6] 또한, 본 발명은 자동으로 엔진을 점화하는 결정에 대한 사용자의 피드백을 반영하여 사용자마다 개인화된 오토 스탑 시스템의 제어가 가능한, 오토 스탑 시스템을 제어하는 인공 지능 장치 및 그 방법을 제공하고자 한다.

과제 해결 수단

[7] 본 발명의 일 실시 예는 현재 차량의 주행 상황을 나타내는 교통 정보 및 주행 정보를 획득하고, 차량이 정차되어 오토 스탑 시스템에 의해 자동으로 엔진이 정지되었을 때 자동으로 엔진을 점화하기 위한 엔진 점화 시점 또는 엔진 점화 여부를 결정하고, 결정된 엔진 점화 시점 또는 엔진 점화 여부에 따라 자동으로 엔진을 점화하는 인공 지능 장치 및 그 방법을 제공한다.

[8] 또한, 본 발명의 일 실시 예는 차량 또는 사용자마다 개인화된 제어 모델을 이용하고, 제어 모델에서 결정된 엔진 점화 시점 또는 엔진 점화 여부에 대한 사용자의 피드백을 획득하여 오토 스탑 시스템 제어 모델을 갱신하는데 이용되는 갱신용 학습 데이터를 생성하고, 갱신용 학습 데이터를 이용하여 갱신된 오토 스탑 시스템 제어 모델을 이용하여 엔진 점화 시점 또는 엔진 점화 여부를 결정하고, 결정된 엔진 점화 시점 또는 엔진 점화 여부에 따라 엔진을 점화하는 인공 지능 장치 및 그 방법을 제공한다.

발명의 효과

[9] 본 발명의 다양한 실시 예에 따르면, 차량이 정차하여 오토 스탑 시스템에 의하여 엔진이 정지된 경우에, 사용자가 출발을 위하여 별도의 조작을 행하지 않더라도 자동으로 출발 가능성이 높다고 판단되는 적당한 시점에 자동으로 엔진을 점화시킬 수 있고, 그에 따라 차량의 출발 지연 문제를 해결하며 사용자의 피로도를 줄일 수 있다.

[10] 또한, 본 발명의 다양한 실시 예에 따르면, 오토 스탑 시스템 제어 모델에 의하여 결정된 오토 스탑 시스템에 의하여 정지된 엔진을 자동으로 점화하는 시점에 대한 사용자의 만족도 또는 선호도 등을 파악하고, 사용자의 만족도 또는 선호도를 반영하여 갱신된 오토 스탑 시스템 제어 모델을 이용하여 엔진 점화 시점을 결정함으로써, 사용자별로 만족도가 높은 개별화된 엔진 자동 점화 기능을 제공할 수 있다.

도면의 간단한 설명

[11] 도 1은 본 발명의 일 실시 예에 따른 오토 스탑 시스템 제어 장치(100)의 구성을 나타낸 블록도이다.

[12] 도 2는 본 발명의 일 실시 예에 따른 인공 신경망의 학습 장치(200)의 구성을 나타낸 블록도이다.

[13] 도 3은 본 발명의 일 실시 예에 따른 오토 스탑 시스템 제어 방법을 나타낸 동작 흐름도이다.

[14] 도 4는 도 3에 도시된 입력 데이터를 획득하는 단계(S301)의 일 예를 나타낸 동작 흐름도이다.

[15] 도 5 및 6은 본 발명의 일 실시 예에 따라 획득하는 입력 데이터의 예시를 나타내는 도면이다.

[16] 도 7은 본 발명의 일 실시 예에 따른 규칙 기반 제어 모델의 예시를 나타낸 도면이다.

[17] 도 8은 본 발명의 일 실시 예에서 연관 규칙 분석에 사용되는 데이터의 형식의 예시를 나타낸 도면이다.

[18] 도 9는 본 발명의 일 실시 예에서 연관 규칙 분석에 따라 생성된 연관 규칙의 예시를 나타낸 도면이다.

[19] 도 10은 본 발명의 일 실시 예에 따른 인공 신경망 기반 제어 모델의 예시를

나타낸 도면이다.

[20] 도 11은 본 발명의 일 실시 예에 따른 인공 신경망 기반 제어 모델의 예시를 나타낸 도면이다.

[21] 도 12는 본 발명의 일 실시 예에 따른 오토 스탑 시스템의 제어 시나리오의 예시를 도시한 도면이다.

발명의 실시를 위한 형태

[22] 이하, 첨부된 도면을 참조하여 본 명세서에 개시된 실시 예를 상세히 설명하되, 도면 부호에 관계없이 동일하거나 유사한 구성요소는 동일한 참조 번호를 부여하고 이에 대한 중복되는 설명은 생략하기로 한다. 이하의 설명에서 사용되는 구성요소에 대한 접미사 "모듈" 및 "부"는 명세서 작성의 용이함만이 고려되어 부여되거나 혼용되는 것으로서, 그 자체로 서로 구별되는 의미 또는 역할을 갖는 것은 아니다. 또한, 본 명세서에 개시된 실시 예를 설명함에 있어서 관련된 공지 기술에 대한 구체적인 설명이 본 명세서에 개시된 실시 예의 요지를 흐릴 수 있다고 판단되는 경우 그 상세한 설명을 생략한다. 또한, 첨부된 도면은 본 명세서에 개시된 실시 예를 쉽게 이해할 수 있도록 하기 위한 것일 뿐, 첨부된 도면에 의해 본 명세서에 개시된 기술적 사상이 제한되지 않으며, 본 발명의 사상 및 기술 범위에 포함되는 모든 변경, 균등물 내지 대체물을 포함하는 것으로 이해되어야 한다.

[23] 제1, 제2 등과 같이 서수를 포함하는 용어는 다양한 구성요소들을 설명하는데 사용될 수 있지만, 상기 구성요소들은 상기 용어들에 의해 한정되지는 않는다. 상기 용어들은 하나의 구성요소를 다른 구성요소로부터 구별하는 목적으로만 사용된다.

[24] 어떤 구성요소가 다른 구성요소에 "연결되어" 있다거나 "접속되어" 있다고 언급된 때에는, 그 다른 구성요소에 직접적으로 연결되어 있거나 또는 접속되어 있을 수도 있지만, 중간에 다른 구성요소가 존재할 수도 있다고 이해되어야 할 것이다. 반면에, 어떤 구성요소가 다른 구성요소에 "직접 연결되어" 있다거나 "직접 접속되어" 있다고 언급된 때에는, 중간에 다른 구성요소가 존재하지 않는 것으로 이해되어야 할 것이다.

[25]

[26] 인공 지능(artificial intelligence, AI)은 인간의 지능으로 할 수 있는 사고, 학습, 자기계발 등을 컴퓨터가 할 수 있도록 하는 방법을 연구하는 컴퓨터 공학 및 정보기술의 한 분야로, 컴퓨터가 인간의 지능적인 행동을 모방할 수 있도록 하는 것을 의미한다.

[27] 또한, 인공지능은 그 자체로 존재하는 것이 아니라, 컴퓨터 과학의 다른 분야와 직간접으로 많은 관련을 맺고 있다. 특히 현대에는 정보기술의 여러 분야에서 인공지능적 요소를 도입하여, 그 분야의 문제 풀이에 활용하려는 시도가 매우 활발하게 이루어지고 있다.

[28] 머신 러닝(machine learning)은 인공지능의 한 분야로, 컴퓨터에 명시적인 프로그램 없이 배울 수 있는 능력을 부여하는 연구 분야이다.

[29] 구체적으로 머신 러닝은, 경험적 데이터를 기반으로 학습을 하고 예측을 수행하고 스스로의 성능을 향상시키는 시스템과 이를 위한 알고리즘을 연구하고 구축하는 기술이라 할 수 있다. 머신 러닝의 알고리즘들은 엄격하게 정해진 정적인 프로그램 명령들을 수행하는 것이라기보다, 입력 데이터를 기반으로 예측이나 결정을 이끌어내기 위해 특정한 모델을 구축하는 방식을 취한다.

[30] 용어 '머신 러닝'은 용어 '기계 학습'과 혼용되어 사용될 수 있다.

[31] 기계 학습에서 데이터를 어떻게 분류할 것인가를 놓고, 많은 기계 학습 알고리즘이 개발되었다. 의사결정나무(Decision Tree)나 베이지안 망(Bayesian network), 서포트벡터머신(SVM: support vector machine), 그리고 인공 신경망(ANN: Artificial Neural Network) 등이 대표적이다.

[32] 의사결정나무는 의사결정규칙(Decision Rule)을 나무구조로 도표화하여 분류와 예측을 수행하는 분석방법이다.

[33] 베이지안 망은 다수의 변수들 사이의 확률적 관계(조건부독립성: conditional independence)를 그래프 구조로 표현하는 모델이다. 베이지안 망은 비지도 학습(unsupervised learning)을 통한 데이터마이닝(data mining)에 적합하다.

[34] 서포트벡터머신은 패턴인식과 자료분석을 위한 지도 학습(supervised learning)의 모델이며, 주로 분류와 회귀분석을 위해 사용한다.

[35] 인공신경망은 생물학적 뉴런의 동작원리와 뉴런간의 연결 관계를 모델링한 것으로 노드(node) 또는 처리 요소(processing element)라고 하는 다수의 뉴런들이 레이어(layer) 구조의 형태로 연결된 정보처리 시스템이다.

[36] 인공 신경망은 기계 학습에서 사용되는 모델로써, 기계학습과 인지과학에서 생물학의 신경망(동물의 중추신경계 중 특히 뇌)에서 영감을 얻은 통계학적 학습 알고리즘이다.

[37] 구체적으로 인공신경망은 시냅스(synapse)의 결합으로 네트워크를 형성한 인공 뉴런(노드)이 학습을 통해 시냅스의 결합 세기를 변화시켜, 문제 해결 능력을 가지는 모델 전반을 의미할 수 있다.

[38] 용어 인공신경망은 용어 뉴럴 네트워크(Neural Network)와 혼용되어 사용될 수 있다.

[39] 인공신경망은 복수의 레이어(layer)를 포함할 수 있고, 레이어들 각각은 복수의 뉴런(neuron)을 포함할 수 있다. 또한 인공신경망은 뉴런과 뉴런을 연결하는 시냅스를 포함할 수 있다.

[40] 인공 신경망은 일반적으로 다음의 세가지 인자, 즉 (1) 다른 레이어의 뉴런들 사이의 연결 패턴 (2) 연결의 가중치를 갱신하는 학습 과정 (3) 이전 레이어로부터 수신되는 입력에 대한 가중 합으로부터 출력값을 생성하는 활성화 함수에 의해 정의될 수 있다.

[41] 인공 신경망은, DNN(Deep Neural Network), RNN(Recurrent Neural Network), BRDNN(Bidirectional Recurrent Deep Neural Network), MLP(Multilayer Perceptron), CNN(Convolutional Neural Network)와 같은 방식의 네트워크 모델들을 포함할 수 있으나, 이에 한정되지 않는다.

[42] 본 명세서에서 용어 '레이어'는 용어 '계층'과 혼용되어 사용될 수 있다.

[43] 인공신경망은 계층 수에 따라 단층 신경망(Single-Layer Neural Networks)과 다층 신경망(Multi-Layer Neural Networks)으로 구분된다.

[44] 일반적인 단층 신경망은, 입력층과 출력층으로 구성된다.

[45] 또한 일반적인 다층 신경망은 입력층(Input Layer)과 하나 이상의 은닉층(Hidden Layer), 출력층(Output Layer)으로 구성된다.

[46] 입력층은 외부의 자료들을 받아들이는 층으로서, 입력층의 뉴런 수는 입력되는 변수의 수와 동일하며, 은닉층은 입력층과 출력층 사이에 위치하며 입력층으로부터 신호를 받아 특성을 추출하여 출력층으로 전달한다. 출력층은 은닉층으로부터 신호를 받고, 수신한 신호에 기반한 출력 값을 출력한다. 뉴런간의 입력신호는 각각의 연결강도(가중치)와 곱해진 후 합산되며 이 합이 뉴런의 임계치보다 크면 뉴런이 활성화되어 활성화 함수를 통하여 획득한 출력값을 출력한다.

[47] 한편 입력층과 출력 층 사이에 복수의 은닉층을 포함하는 심층 신경망은, 기계 학습 기술의 한 종류인 딥 러닝을 구현하는 대표적인 인공 신경망일 수 있다.

[48] 한편 용어 '딥 러닝'은 용어 '심층 학습'과 혼용되어 사용될 수 있다.

[49] 인공 신경망은 훈련 데이터(training data)를 이용하여 학습(training)될 수 있다. 여기서 학습이란, 입력 데이터를 분류(classification)하거나 회귀분석(regression)하거나 군집화(clustering)하는 등의 목적을 달성하기 위하여, 학습 데이터를 이용하여 인공 신경망의 파라미터(parameter)를 결정하는 과정을 의미할 수 있다. 인공 신경망의 파라미터의 대표적인 예시로써, 시냅스에 부여되는 가중치(weight)나 뉴런에 적용되는 편향(bias)을 들 수 있다.

[50] 훈련 데이터에 의하여 학습된 인공 신경망은, 입력 데이터를 입력 데이터가 가지는 패턴에 따라 분류하거나 군집화 할 수 있다.

[51] 한편 훈련 데이터를 이용하여 학습된 인공 신경망을, 본 명세서에서는 학습 모델(a trained model)이라 명칭 할 수 있다.

[52] 다음은 인공 신경망의 학습 방식에 대하여 설명한다.

[53] 인공 신경망의 학습 방식은 크게, 지도 학습, 비 지도 학습, 준 지도 학습(Semi-Supervised Learning), 강화 학습(Reinforcement Learning)으로 분류될 수 있다.

[54] 지도 학습은 훈련 데이터로부터 하나의 함수를 유추해내기 위한 기계 학습의 한 방법이다.

[55] 그리고 이렇게 유추되는 함수 중, 연속 적인 값을 출력하는 것을 회귀분석(Regression)이라 하고, 입력 벡터의 클래스(class)를 예측하여 출력하는

것을 분류(Classification)라고 할 수 있다.

[56] 지도 학습에서는, 훈련 데이터에 대한 레이블(label)이 주어진 상태에서 인공 신경망을 학습시킨다.

[57] 여기서 레이블이란, 훈련 데이터가 인공 신경망에 입력되는 경우 인공 신경망이 추론해 내야 하는 정답(또는 결과 값)을 의미할 수 있다.

[58] 본 명세서에서는 훈련 데이터가 입력되는 경우 인공 신경망이 추론해 내야 하는 정답(또는 결과값)을 레이블 또는 레이블링 데이터(labeling data)이라 명칭 한다.

[59] 또한 본 명세서에서는, 인공 신경망의 학습을 위하여 훈련 데이터에 레이블을 설정하는 것을, 훈련 데이터에 레이블링 데이터를 레이블링(labeling) 한다고 명칭 한다.

[60] 이 경우 훈련 데이터와 훈련 데이터에 대응하는 레이블)은 하나의 트레이닝 셋(training set)을 구성하고, 인공 신경망에는 트레이닝 셋의 형태로 입력될 수 있다.

[61] 한편 훈련 데이터는 복수의 특징(feature)을 나타내고, 훈련 데이터에 레이블이 레이블링 된다는 것은 훈련 데이터가 나타내는 특징에 레이블이 달린다는 것을 의미할 수 있다. 이 경우 훈련 데이터는 입력 개체의 특징을 벡터 형태로 나타낼 수 있다.

[62] 인공 신경망은 훈련 데이터와 레이블링 데이터를 이용하여, 훈련 데이터와 레이블링 데이터의 연관 관계에 대한 함수를 유추할 수 있다. 그리고, 인공 신경망에서 유추된 함수에 대한 평가를 통해 인공 신경망의 파라미터가 결정(최적화)될 수 있다.

[63] 비 지도 학습은 기계 학습의 일종으로, 훈련 데이터에 대한 레이블이 주어지지 않는다.

[64] 구체적으로, 비 지도 학습은, 훈련 데이터 및 훈련 데이터에 대응하는 레이블의 연관 관계 보다는, 훈련 데이터 자체에서 패턴을 찾아 분류하도록 인공 신경망을 학습시키는 학습 방법일 수 있다.

[65] 비 지도 학습의 예로는, 군집화 또는 독립 성분 분석(Independent Component Analysis)을 들 수 있다.

[66] 본 명세서에서 용어 '군집화'는 용어 '클러스터링'과 혼용되어 사용될 수 있다.

[67] 비지도 학습을 이용하는 인공 신경망의 일례로 생성적 적대 신경망(GAN: Generative Adversarial Network), 오토 인코더(AE: Autoencoder)를 들 수 있다.

[68] 생성적 적대 신경망이란, 생성기(generator)와 판별기(discriminator), 두 개의 서로 다른 인공지능이 경쟁하며 성능을 개선하는 머신 러닝 방법이다.

[69] 이 경우 생성기는 새로운 데이터를 창조하는 모형으로, 원본 데이터를 기반으로 새로운 데이터를 생성할 수 있다.

[70] 또한 판별기는 데이터의 패턴을 인식하는 모형으로, 입력되는 데이터가 원본 데이터인지 또는 생성기에서 생성한 가짜 데이터인지 여부를 감별하는 역할을

수행할 수 있다.

[71] 그리고 생성기는 판별기를 속이지 못한 데이터를 입력 받아 학습하며, 판별기는 생성기로부터 속은 데이터를 입력 받아 학습할 수 있다. 이에 따라 생성기는 판별기를 최대한 잘 속이도록 진화할 수 있고, 판별기의 원본 데이터와 생성기에 의해 생성된 데이터를 잘 구분하도록 진화할 수 있다.

[72] 오토 인코더는 입력 자체를 출력으로 재현하는 것을 목표로 하는 신경망이다.

[73] 오토 인코더는 입력층, 적어도 하나의 은닉층 및 출력층을 포함한다.

[74] 이 경우 은닉 계층의 노드 수가 입력 계층의 노드 수보다 적으므로 데이터의 차원이 줄어들게 되며, 이에 따라 압축 또는 인코딩이 수행되게 된다.

[75] 또한 은닉 계층에서 출력한 데이터는 출력 계층으로 들어간다. 이 경우 출력 계층의 노드 수는 은닉 계층의 노드 수보다 많으므로, 데이터의 차원이 늘어나게 되며, 이에 따라 압축 해제 또는 디코딩이 수행되게 된다.

[76] 한편 오토 인코더는 학습을 통해 뉴런의 연결 강도를 조절함으로써 입력 데이터가 은닉층 데이터로 표현된다. 은닉층에서는 입력층보다 적은 수의 뉴런으로 정보를 표현하는데 입력 데이터를 출력으로 재현할 수 있다는 것은, 은닉층이 입력 데이터로부터 숨은 패턴을 발견하여 표현했다는 것을 의미할 수 있다.

[77] 준 지도 학습은 기계 학습의 일종으로, 레이블이 주어진 훈련 데이터와 레이블이 주어지지 않은 훈련 데이터를 모두 사용하는 학습 방법을 의미할 수 있다.

[78] 준 지도 학습의 기법 중 하나로, 레이블이 주어지지 않은 훈련 데이터의 레이블을 추론한 후 추론된 라벨을 이용하여 학습을 수행하는 기법이 있으며, 이러한 기법은 레이블링에 소요되는 비용이 큰 경우에 유용하게 사용될 수 있다.

[79] 강화 학습은, 에이전트(Agent)가 매 순간 어떤 행동을 해야 좋을지 판단할 수 있는 환경이 주어진다면, 데이터 없이 경험으로 가장 좋을 길을 찾을 수 있다는 이론이다.

[80] 강화 학습은 주로 마르코프 결정 과정(MDP: Markov Decision Process)에 의하여 수행될 수 있다.

[81] 마르코프 결정 과정을 설명하면, 첫 번째로 에이전트가 다음 행동을 하기 위해 필요한 정보들이 구성된 환경이 주어지며, 두 번째로 그 환경에서 에이전트가 어떻게 행동할지 정의하고, 세 번째로 에이전트가 무엇을 잘하면 보상(reward)를 주고 무엇을 못하면 벌점(penalty)을 줄지 정의하며, 네 번째로 미래의 보상이 최고점에 이를 때까지 반복 경험하여 최적의 정책(policy)을 도출하게 된다.

[82] 인공 신경망은 모델의 구성, 활성 함수(Activation Function), 손실 함수(Loss Function) 또는 비용 함수(Cost Function), 학습 알고리즘, 최적화 알고리즘 등에 의해 그 구조가 특정되며, 학습 전에 하이퍼파라미터(Hyperparameter)가 미리 설정되고, 이후에 학습을 통해 모델 파라미터(Model Parameter)가 설정되어 내용이 특정될 수 있다.

[83] 예컨대, 인공 신경망의 구조를 결정하는 요소에는 은닉층의 개수, 각 은닉층에 포함된 은닉 노드의 개수, 입력 특징 벡터(Input Feature Vector), 대상 특징 벡터(Target Feature Vector) 등이 포함될 수 있다.

[84] 하이퍼파라미터는 모델 파라미터의 초기값 등과 같이 학습을 위하여 초기에 설정하여야 하는 여러 파라미터들을 포함한다. 그리고, 모델 파라미터는 학습을 통하여 결정하고자 하는 여러 파라미터들을 포함한다.

[85] 예컨대, 하이퍼파라미터에는 노드 간 가중치 초기값, 노드 간 편향 초기값, 미니 배치(Mini-batch) 크기, 학습 반복 횟수, 학습률(Learning Rate) 등이 포함될 수 있다. 그리고, 모델 파라미터에는 노드 간 가중치, 노드 간 편향 등이 포함될 수 있다.

[86] 손실 함수는 인공 신경망의 학습 과정에서 최적의 모델 파라미터를 결정하기 위한 지표(기준)로 이용될 수 있다. 인공 신경망에서 학습은 손실 함수를 줄이기 위하여 모델 파라미터들을 조작하는 과정을 의미하며, 학습의 목적은 손실 함수를 최소화하는 모델 파라미터를 결정하는 것으로 볼 수 있다.

[87] 손실 함수는 주로 평균 제곱 오차(MSE: Mean Squared Error) 또는 교차 엔트로피 오차(CEE, Cross Entropy Error)를 사용할 수 있으며, 본 발명이 이에 한정되지는 않는다.

[88] 교차 엔트로피 오차는 정답 레이블이 원 핫 인코딩(one-hot encoding)된 경우에 사용될 수 있다. 원 핫 인코딩은 정답에 해당하는 뉴런에 대하여만 정답 레이블 값을 1로, 정답이 아닌 뉴런은 정답 레이블 값이 0으로 설정하는 인코딩 방법이다.

[89] 머신 러닝 또는 딥 러닝에서는 손실 함수를 최소화하기 위하여 학습 최적화 알고리즘을 이용할 수 있으며, 학습 최적화 알고리즘에는 경사 하강법(GD: Gradient Descent), 확률적 경사 하강법(SGD: Stochastic Gradient Descent), 모멘텀(Momentum), NAG(Nesterov Accelerate Gradient), Adagrad, AdaDelta, RMSProp, Adam, Nadam 등이 있다.

[90] 경사 하강법은 현재 상태에서 손실 함수의 기울기를 고려하여 손실 함수값을 줄이는 방향으로 모델 파라미터를 조정하는 기법이다.

[91] 모델 파라미터를 조정하는 방향은 스텝(step) 방향, 조정하는 크기는 스텝 사이즈(size)라고 칭한다.

[92] 이때, 스텝 사이즈는 학습률을 의미할 수 있다.

[93] 경사 하강법은 손실 함수를 각 모델 파라미터들로 편미분하여 기울기를 획득하고, 모델 파라미터들을 획득한 기울기 방향으로 학습률만큼 변경하여 갱신할 수 있다.

[94] 확률적 경사 하강법은 학습 데이터를 미니 배치로 나누고, 각 미니 배치마다 경사 하강법을 수행하여 경사 하강의 빈도를 높인 기법이다.

[95] Adagrad, AdaDelta 및 RMSProp는 SGD에서 스텝 사이즈를 조절하여 최적화 정확도를 높이는 기법이다. SGD에서 모멘텀 및 NAG는 스텝 방향을 조절하여

최적화 정확도를 높이는 기법이다. Adam은 모멘텀과 RMSProp를 조합하여 스텝 사이즈와 스텝 방향을 조절하여 최적화 정확도를 높이는 기법이다. Nadam은 NAG와 RMSProp를 조합하여 스텝 사이즈와 스텝 방향을 조절하여 최적화 정확도를 높이는 기법이다.

[96] 인공 신경망의 학습 속도와 정확도는 인공 신경망의 구조와 학습 최적화 알고리즘의 종류뿐만 아니라, 하이퍼파라미터에 크게 좌우되는 특징이 있다. 따라서, 좋은 학습 모델을 획득하기 위하여는 적당한 인공 신경망의 구조와 학습 알고리즘을 결정하는 것뿐만 아니라, 적당한 하이퍼파라미터를 설정하는 것이 중요하다.

[97] 통상적으로 하이퍼파라미터는 실험적으로 다양한 값으로 설정해가며 인공 신경망을 학습시켜보고, 학습 결과 안정적인 학습 속도와 정확도를 제공하는 최적의 값으로 설정한다.

[98]

[99] 이하에서, 오토 스탑 시스템을 제어하는 것은 오토 스탑 기능을 제어하는 것으로 이해될 수 있다. 따라서, 오토 스탑 시스템 제어 장치와 오토 스탑 기능 제어 장치는 서로 동일한 의미로 혼용되어 사용될 수 있으며, 오토 스탑 시스템 제어 방법과 오토 스탑 기능 제어 방법은 서로 동일한 의미로 혼용되어 사용될 수 있다.

[100] 또한, 오토 스탑 시스템 제어 모델은 오토 스탑 기능 제어 모델과 서로 동일한 의미로 혼용되어 사용될 수 있다.

[101]

[102] 도 1은 본 발명의 일 실시 예에 따른 오토 스탑 시스템 제어 장치(100)의 구성을 나타낸 블록도이다.

[103] 이하에서, 오토 스탑 시스템 제어 장치(100)는 단말기(100)라 칭할 수 있다.

[104] 단말기(100)는 텔레비전(TV), 프로젝터, 휴대폰, 스마트 폰(smart phone), 노트북 컴퓨터(laptop computer), 디지털방송용 단말기, PDA(personal digital assistants), PMP(portable multimedia player), 네비게이션, 슬레이트 PC(slate PC), 태블릿 PC(tablet PC), 울트라북(ultrabook), 웨어러블 디바이스(wearable device, 예를 들어, 워치형 단말기 (smartwatch), 글래스형 단말기 (smart glass), HMD(head mounted display)), 셋톱박스(STB), DMB 수신기, 라디오, 세탁기, 냉장고, 데스크탑 컴퓨터, 디지털사이니지와 같은 고정형 기기 및 이동 가능한 기기 등으로 구현될 수 있다.

[105] 즉, 단말기(100)는 가정에서 이용하는 다양한 가전의 형태로 구현될 수 있으며, 고정 또는 이동 가능한 로봇에도 적용될 수 있다.

[106] 특히, 단말기(100)는 차량에 탑재되는 네비게이션 및 멀티미디어 장치로 구현될 수 있고, 나아가, 차량의 전자제어유닛(ECU: Electronic Control Unit)과 연결되거나 전자제어유닛을 포함하는 장치로 구현될 수 있다.

[107] 단말기(100)는 음성 에이전트의 기능을 수행할 수 있다. 음성 에이전트는

사용자의 음성을 인식하고, 인식된 사용자의 음성에 적합한 응답을 음성으로 출력하는 프로그램일 수 있다.

[108] 도 1을 참조하면, 단말기(100)는 무선 통신부(Wireless Communication Unit, 110), 입력부(Input Unit, 120), 러닝 프로세서(Learning Processor, 130), 센싱부(Sensing Unit, 140), 출력부(Output Unit, 150), 인터페이스부(Interface Unit, 160), 메모리(Memory, 170), 프로세서(Processor, 180) 및 전원 공급부(Power Supply Unit, 190) 등을 포함할 수 있다.

[109] 학습 모델(a trained model)은 단말기(100)에 탑재될 수 있다.

[110] 한편, 학습 모델은 하드웨어, 소프트웨어 또는 하드웨어와 소프트웨어의 조합으로 구현될 수 있으며, 학습 모델의 일부 또는 전부가 소프트웨어로 구현되는 경우 학습 모델을 구성하는 하나 이상의 명령어는 메모리(170)에 저장될 수 있다.

[111] 무선 통신부(110)는 방송 수신 모듈(Broadcast Receiving Module, 111), 이동통신 모듈(Mobile Communication Unit, 112), 무선 인터넷 모듈(Wireless Internet Module, 113), 근거리 통신 모듈(Short Range Communication Module, 114), 위치정보 모듈(Location Information Module, 115) 중 적어도 하나를 포함할 수 있다.

[112] 방송 수신 모듈(111)은 방송 채널을 통하여 외부의 방송 관리 서버로부터 방송 신호 및/또는 방송 관련된 정보를 수신한다.

[113] 이동통신 모듈(112)은, 이동통신을 위한 기술표준들 또는 통신방식(예를 들어, GSM(Global System for Mobile communication), CDMA(Code Division Multi Access), CDMA2000(Code Division Multi Access 2000), EV-DO(Enhanced Voice-Data Optimized or Enhanced Voice-Data Only), WCDMA(Wideband CDMA), HSDPA(High Speed Downlink Packet Access), HSUPA(High Speed Uplink Packet Access), LTE(Long Term Evolution), LTE-A(Long Term Evolution-Advanced) 등)에 따라 구축된 이동 통신망 상에서 기지국, 외부의 단말, 서버 중 적어도 하나와 무선 신호를 송수신한다.

[114] 무선 인터넷 모듈(113)은 무선 인터넷 접속을 위한 모듈을 말하는 것으로, 단말기(100)에 내장되거나 외장될 수 있다. 무선 인터넷 모듈(113)은 무선 인터넷 기술들에 따른 통신망에서 무선 신호를 송수신하도록 이루어진다.

[115] 무선 인터넷 기술로는, 예를 들어 WLAN(Wireless LAN), Wi-Fi(Wireless-Fidelity), Wi-Fi(Wireless Fidelity) Direct, DLNA(Digital Living Network Alliance), WiBro(Wireless Broadband), WiMAX(World Interoperability for Microwave Access), HSDPA(High Speed Downlink Packet Access), HSUPA(High Speed Uplink Packet Access), LTE(Long Term Evolution), LTE-A(Long Term Evolution-Advanced) 등이 있다.

[116] 근거리 통신 모듈(114)은 근거리 통신(Short range communication)을 위한 것으로서, 블루투스(Bluetooth™), RFID(Radio Frequency Identification), 적외선

통신(Infrared Data Association; IrDA), UWB(Ultra Wideband), ZigBee, NFC(Near Field Communication), Wi-Fi(Wireless-Fidelity), Wi-Fi Direct, Wireless USB(Wireless Universal Serial Bus) 기술 중 적어도 하나를 이용하여, 근거리 통신을 지원할 수 있다.

[117] 위치정보 모듈(115)은 단말기의 위치(또는 현재 위치)를 획득하기 위한 모듈로서, 그의 대표적인 예로는 GPS(Global Positioning System) 모듈 또는 WiFi(Wireless Fidelity) 모듈이 있다. 예를 들어, 단말기는 GPS모듈을 활용하면, GPS 위성에서 보내는 신호를 이용하여 단말기의 위치를 획득할 수 있다.

[118] 입력부(120)는 영상 신호 입력을 위한 카메라(Camera, 121), 오디오 신호를 수신하기 위한 마이크로폰(Microphone, 122), 사용자로부터 정보를 입력 받기 위한 사용자 입력부(User Input Unit, 123)를 포함할 수 있다.

[119] 입력부(120)에서 수집한 음성 데이터나 이미지 데이터는 분석되어 사용자의 제어 명령으로 처리될 수 있다.

[120] 입력부(120)는 모델 학습을 위한 훈련 데이터 및 학습된 모델을 이용하여 출력을 획득할 때 사용될 입력 데이터 등을 획득할 수 있다.

[121] 입력부(120)는 가공되지 않은 입력 데이터를 획득할 수도 있으며, 이 경우 프로세서(180) 또는 러닝 프로세서(130)는 획득한 데이터를 전처리하여 모델 학습에 입력이 가능한 훈련 데이터 또는 전처리된 입력 데이터를 생성할 수 있다.

[122] 이때, 입력 데이터에 대한 전처리는, 입력 데이터로부터 입력 특징점(input feature)을 추출하는 것을 의미할 수 있다.

[123] 입력부(120)는 영상 정보(또는 신호), 오디오 정보(또는 신호), 데이터, 또는 사용자로부터 입력되는 정보의 입력을 위한 것으로서, 영상 정보의 입력을 위하여, 단말기(100)는 하나 또는 복수의 카메라(121)들을 구비할 수 있다.

[124] 카메라(121)는 화상 통화모드 또는 촬영 모드에서 이미지 센서에 의해 얻어지는 정지영상 또는 동영상 등의 화상 프레임을 처리한다. 처리된 화상 프레임은 디스플레이부(Display Unit, 151)에 표시되거나 메모리(170)에 저장될 수 있다.

[125] 마이크로폰(122)은 외부의 음향 신호를 전기적인 음성 데이터로 처리한다. 처리된 음성 데이터는 단말기(100)에서 수행 중인 기능(또는 실행 중인 응용 프로그램)에 따라 다양하게 활용될 수 있다. 한편, 마이크로폰(122)에는 외부의 음향 신호를 입력 받는 과정에서 발생되는 잡음(noise)을 제거하기 위한 다양한 잡음 제거 알고리즘이 구현될 수 있다.

[126] 사용자 입력부(123)는 사용자로부터 정보를 입력 받기 위한 것으로서, 사용자 입력부(123)를 통해 정보가 입력되면, 프로세서(180)는 입력된 정보에 대응되도록 단말기(100)의 동작을 제어할 수 있다.

[127] 사용자 입력부(123)는 기계식 (mechanical) 입력수단(또는, 메커니컬 키, 예를 들어, 단말기(100)의 전/후면 또는 측면에 위치하는 버튼, 돔 스위치 (dome

switch), 조그 휠, 조그 스위치 등) 및 터치식 입력수단을 포함할 수 있다. 일 예로서, 터치식 입력수단은, 소프트웨어적인 처리를 통해 터치스크린에 표시되는 가상 키(virtual key), 소프트 키(soft key) 또는 비주얼 키(visual key)로 이루어지거나, 상기 터치스크린 이외의 부분에 배치되는 터치 키(touch key)로 이루어질 수 있다.

[128] 러닝 프로세서(130)는 훈련 데이터를 이용하여 인공 신경망으로 구성된 모델을 학습한다.

[129] 구체적으로, 러닝 프로세서(130)는 앞서 설명한 다양한 학습 기법을 이용하여 인공 신경망을 반복적으로 학습시킴으로써, 인공 신경망의 최적화된 모델 파라미터들을 결정할 수 있다

[130] 본 명세서에서는 훈련 데이터를 이용하여 학습됨으로써 파라미터가 결정된 인공 신경망을 학습 모델 또는 학습된 모델(a trained model)이라 칭할 수 있다.

[131] 이때, 학습 모델은 훈련 데이터가 아닌 새로운 입력 데이터에 대하여 결과 값을 추론해 내는데 사용될 수 있다.

[132] 러닝 프로세서(130)는 데이터 마이닝, 데이터 분석, 지능형 의사 결정 및 기계 학습 알고리즘을 위해 이용될 정보를 수신, 분류, 저장 및 출력하도록 구성될 수 있다.

[133] 러닝 프로세서(130)는 다른 컴포넌트, 디바이스, 단말기 또는 단말기와 통신하는 장치에 의해 수신, 검출, 감지, 생성, 사전 정의 또는 다른 방식으로 출력되는 데이터를 저장하도록 구성된 하나 이상의 메모리 유닛을 포함할 수 있다.

[134] 러닝 프로세서(130)는 단말기에 통합되거나 구현된 메모리를 포함할 수 있다. 일부 실시 예에서, 러닝 프로세서(130)는 메모리(170)를 사용하여 구현될 수 있다.

[135] 선택적으로 또는 부가적으로, 러닝 프로세서(130)는 단말기에 직접 결합된 외부 메모리 또는 단말기와 통신하는 서버에서 유지되는 메모리와 같이 단말기와 관련된 메모리를 사용하여 구현될 수 있다.

[136] 다른 실시 예에서, 러닝 프로세서(130)는 클라우드 컴퓨팅 환경에서 유지되는 메모리, 또는 네트워크와 같은 통신 방식을 통해 단말기에 의해 액세스 가능한 다른 원격 메모리 위치를 이용하여 구현될 수 있다.

[137] 러닝 프로세서(130)는 일반적으로 감독 또는 감독되지 않은 학습, 데이터 마이닝, 예측 분석 또는 다른 머신에서 사용하기 위해 데이터를 식별, 색인화, 카테고리화, 조작, 저장, 검색 및 출력하기 위해 데이터를 하나 이상의 데이터베이스에 저장하도록 구성될 수 있다. 여기서, 데이터베이스는 메모리(170), 학습 장치(200)의 메모리(230), 클라우드 컴퓨팅 환경에서 유지되는 메모리, 또는 네트워크와 같은 통신 방식을 통해 단말기에 의해 액세스 가능한 다른 원격 메모리 위치를 이용하여 구현될 수 있다.

[138] 러닝 프로세서(130)에 저장된 정보는 다양한 상이한 유형의 데이터 분석

알고리즘 및 기계 학습 알고리즘 중 임의의 것을 사용하여 프로세서(180) 또는 단말기의 하나 이상의 다른 제어기에 의해 이용될 수 있다.

[139] 이러한, 알고리즘의 예로는, k-최근 인접 시스템, 퍼지 논리 (예: 가능성 이론), 신경 회로망, 볼츠만 기계, 벡터 양자화, 펄스 신경망, 지원 벡터 기계, 최대 마진 분류기, 힐 클라이밍, 유도 논리 시스템 베이지안 네트워크, 페리트넷 (예: 유한 상태 머신, 밀리 머신, 무어 유한 상태 머신), 분류기 트리 (예: 퍼셉트론 트리, 지원 벡터 트리, 마코프 트리, 의사 결정 트리 포리스트, 임의의 포리스트), 판독 모델 및 시스템, 인공 융합, 센서 융합, 이미지 융합, 보강 학습, 증강 현실, 패턴 인식, 자동화 된 계획 등을 포함한다.

[140] 프로세서(180)는 데이터 분석 및 기계 학습 알고리즘을 사용하여 결정되거나, 생성된 정보에 기초하여 단말기의 적어도 하나의 실행 가능한 동작을 결정 또는 예측할 수 있다. 이를 위해, 프로세서(180)는 러닝 프로세서(130)의 데이터를 요청, 검색, 수신 또는 활용할 수 있고, 상기 적어도 하나의 실행 가능한 동작 중 예측되는 동작이나, 바람직한 것으로 판단되는 동작을 실행하도록 상기 단말기를 제어할 수 있다.

[141] 프로세서(180)는 지능적 에뮬레이션(즉, 지식 기반 시스템, 추론 시스템 및 지식 획득 시스템)을 구현하는 다양한 기능을 수행할 수 있다. 이는 적응 시스템, 기계 학습 시스템, 인공 신경망 등을 포함하는, 다양한 유형의 시스템(예컨대, 퍼지 논리 시스템)에 적용될 수 있다.

[142] 프로세서(180)는, 또한 I/O 처리 모듈, 환경 조건 모듈, 음성 - 텍스트 (STT: Speech to Text) 처리 모듈, 자연어 처리 모듈, 작업 흐름 처리 모듈 및 서비스 처리 모듈과 같이, 음성 및 자연 언어 음성 처리를 수반하는 연산을 가능하게 하는 서브 모듈을 포함할 수 있다.

[143] 이들 서브 모듈들 각각은, 단말기에서의 하나 이상의 시스템 또는 데이터 및 모델, 또는 이들의 서브셋 또는 수퍼 셋에 대한 액세스를 가질 수 있다. 또한, 이들 서브 모듈들 각각은, 어휘 색인, 사용자 데이터, 작업 흐름 모델, 서비스 모델 및 자동 음성 인식 (ASR) 시스템을 비롯한 다양한 기능을 제공할 수 있다.

[144] 다른 실시 예에서, 프로세서(180) 또는 단말기의 다른 양태는 상기 서브 모듈, 시스템, 또는 데이터 및 모델로 구현될 수 있다.

[145] 일부 예에서, 러닝 프로세서(130)의 데이터에 기초하여, 프로세서(180)는 사용자 입력 또는 자연 언어 입력으로 표현된 문맥 조건 또는 사용자의 의도에 기초하여 요구 사항을 검출하고 감지하도록 구성될 수 있다.

[146] 프로세서(180)는 문맥 조건 또는 사용자의 의도에 기초하여 요구 사항을 완전히 결정하는데 필요한 정보를 능동적으로 이끌어 내고, 획득할 수 있다. 예를 들어, 프로세서(180)는 입력 기록 및 출력 기록, 패턴 매칭, 모호하지 않은 단어, 입력 의도 등을 포함하는 과거 데이터를 분석함으로써 요구 사항을 결정하는데, 필요한 정보를 능동적으로 이끌어낼 수 있다.

[147] 프로세서(180)는 문맥 조건 또는 사용자의 의도에 기초하여 요구 사항에

응답하는 기능을 실행하기 위한 태스크 흐름을 결정할 수 있다.

[148] 프로세서(180)는 러닝 프로세서(130)에서 프로세싱 및 저장을 위한 정보를 수집하기 위해, 단말기에서 하나 이상의 감지 컴포넌트를 통해 데이터 분석 및 기계 학습 작업에 사용되는 신호 또는 데이터를 수집, 감지, 추출, 검출 및/또는 수신하도록 구성될 수 있다.

[149] 정보 수집은 센서를 통해 정보를 감지하는 것, 메모리(170)에 저장된 정보를 추출하는 것 또는 통신 수단을 통해 다른 단말기, 엔티티 또는 외부 저장 장치로부터 정보를 수신하는 것을 포함할 수 있다.

[150] 프로세서(180)는 단말기에서 사용 히스토리 정보를 수집하여, 메모리(170)에 저장할 수 있다.

[151] 프로세서(180)는 저장된 사용 히스토리 정보 및 예측 모델링을 사용하여 특정 기능을 실행하기 위한 최상의 매치를 결정할 수 있다.

[152] 프로세서(180)는 센싱부(140)를 통해 주변 환경 정보 또는 기타 정보를 수신하거나 감지할 수 있다.

[153] 프로세서(180)는 무선 통신부(110)을 통해 방송 신호 및/또는 방송 관련 정보, 무선 신호, 무선 데이터를 수신할 수 있다.

[154] 프로세서(180)는 입력부(120)로부터 이미지 정보 (또는 해당 신호), 오디오 정보 (또는 해당 신호), 데이터 또는 사용자 입력 정보를 수신할 수 있다.

[155] 프로세서(180)는 정보를 실시간으로 수집하고, 정보 (예를 들어, 지식 그래프, 명령 정책, 개인화 데이터베이스, 대화 엔진 등)를 처리 또는 분류하고, 처리 된 정보를 메모리(170) 또는 러닝 프로세서(130)에 저장할 수 있다.

[156] 단말기의 동작이 데이터 분석 및 기계 학습 알고리즘 및 기술에 기초하여 결정될 때, 프로세서(180)는 결정된 동작을 실행하기 위해 단말기의 구성 요소를 제어할 수 있다. 그리고 프로세서(180)는 제어 명령에 따라 단말을 제어하여 결정된 동작을 수행할 수 있다.

[157] 프로세서(180)는 특정 동작이 수행되는 경우, 데이터 분석 및 기계 학습 알고리즘 및 기법을 통해 특정 동작의 실행을 나타내는 이력 정보를 분석하고, 분석된 정보에 기초하여 이전에 학습 한 정보의 업데이트를 수행할 수 있다.

[158] 따라서, 프로세서(180)는 러닝 프로세서(130)과 함께, 업데이트 된 정보에 기초하여 데이터 분석 및 기계 학습 알고리즘 및 기법의 미래 성능의 정확성을 향상시킬 수 있다.

[159] 센싱부(140)는 단말기 내 정보, 단말기를 둘러싼 주변 환경 정보 및 사용자 정보 중 적어도 하나를 센싱 하기 위한 하나 이상의 센서를 포함할 수 있다.

[160] 예를 들어, 센싱부(140)는 근접센서(proximity sensor), 조도 센서(illumination sensor), 터치 센서(touch sensor), 가속도 센서(acceleration sensor), 자기 센서(magnetic sensor), 중력 센서(G-sensor), 자이로스코프 센서(gyroscope sensor), 모션 센서(motion sensor), RGB 센서, 적외선 센서(IR 센서: infrared sensor), 지문인식 센서(finger scan sensor), 초음파 센서(ultrasonic sensor), 광 센서(optical

sensor, 예를 들어, 카메라(121 참조)), 마이크로폰(microphone, 122 참조), 배터리 게이지(battery gauge), 환경 센서(예를 들어, 기압계, 습도계, 온도계, 방사능 감지 센서, 열 감지 센서, 가스 감지 센서 등), 화학 센서(예를 들어, 전자 코, 헬스케어 센서, 생체 인식 센서 등) 중 적어도 하나를 포함할 7수 있다. 한편, 본 명세서에 개시된 단말기는, 이러한 센서들 중 적어도 둘 이상의 센서에서 센싱되는 정보들을 조합하여 활용할 수 있다.

[161] 출력부(150)는 시각, 청각 또는 촉각 등과 관련된 출력을 발생시키기 위한 것으로, 디스플레이부(Display Unit, 151), 음향 출력부(Sound Output Unit, 152), 햅틱 모듈(Haptic Module, 153), 광 출력부(Optical Output Unit, 154) 중 적어도 하나를 포함할 수 있다.

[162] 디스플레이부(151)는 단말기(100)에서 처리되는 정보를 표시(출력)한다. 예를 들어, 디스플레이부(151)는 단말기(100)에서 구동되는 응용 프로그램의 실행화면 정보, 또는 이러한 실행화면 정보에 따른 UI(User Interface), GUI(Graphic User Interface) 정보를 표시할 수 있다.

[163] 디스플레이부(151)는 터치 센서와 상호 레이어 구조를 이루거나 일체형으로 형성됨으로써, 터치 스크린을 구현할 수 있다. 이러한 터치 스크린은, 단말기(100)와 사용자 사이의 입력 인터페이스를 제공하는 사용자 입력부(123)로써 기능함과 동시에, 단말기(100)와 사용자 사이의 출력 인터페이스를 제공할 수 있다.

[164] 음향 출력부(152)는 호신호 수신, 통화모드 또는 녹음 모드, 음성인식 모드, 방송수신 모드 등에서 무선 통신부(110)로부터 수신되거나 메모리(170)에 저장된 오디오 데이터를 출력할 수 있다.

[165] 음향 출력부(152)는 리시버(receiver), 스피커(speaker), 버저(buzzer) 중 적어도 하나 이상을 포함할 수 있다.

[166] 햅틱 모듈(haptic module)(153)은 사용자가 느낄 수 있는 다양한 촉각 효과를 발생시킨다. 햅틱 모듈(153)이 발생시키는 촉각 효과의 대표적인 예로는 진동이 될 수 있다.

[167] 광출력부(154)는 단말기(100)의 광원의 빛을 이용하여 이벤트 발생을 알리기 위한 신호를 출력한다. 단말기(100)에서 발생 되는 이벤트의 예로는 메시지 수신, 호 신호 수신, 부재중 전화, 알람, 일정 알림, 이메일 수신, 애플리케이션을 통한 정보 수신 등이 될 수 있다.

[168] 인터페이스부(160)는 단말기(100)에 연결되는 다양한 종류의 외부 기기와의 통로 역할을 수행한다. 이러한 인터페이스부(160)는, 유/무선 헤드셋 포트(port), 외부 충전기 포트(port), 유/무선 데이터 포트(port), 메모리 카드(memory card) 포트, 식별 모듈이 구비된 장치를 연결하는 포트(port), 오디오 I/O(Input/Output) 포트(port), 비디오 I/O(Input/Output) 포트(port), 이어폰 포트(port)중 적어도 하나를 포함할 수 있다. 단말기(100)에서는, 상기 인터페이스부(160)에 외부 기기가 연결되는 것에 대응하여, 연결된 외부 기기와 관련된 적절할 제어를

수행할 수 있다.

[169] 한편, 식별 모듈은 단말기(100)의 사용 권한을 인증하기 위한 각종 정보를 저장한 칩으로서, 사용자 인증 모듈(user identify module; UIM), 가입자 인증 모듈(subscriber identity module; SIM), 범용 사용자 인증 모듈(universal subscriber identity module; USIM) 등을7 포함할 수 있다. 식별 모듈이 구비된 장치(이하 '식별 장치')는, 스마트 카드(smart card) 형식으로 제작될 수 있다. 따라서 식별 장치는 상기 인터페이스부(160)를 통하여 단말기(100)와 연결될 수 있다.

[170] 메모리(170)는 단말기(100)의 다양한 기능을 지원하는 데이터를 저장한다.

[171] 메모리(170)는 단말기(100)에서 구동되는 다수의 응용 프로그램(application program 또는 애플리케이션(application)), 단말기(100)의 동작을 위한 데이터들, 명령어들을, 러닝 프로세서(130)의 동작을 위한 데이터들(예를 들어, 머신 러닝을 위한 적어도 하나의 알고리즘 정보 등)을 저장할 수 있다.

[172] 메모리(170)는 러닝 프로세서(130) 또는 학습 장치(200)에서 학습된 모델을 저장할 수 있다.

[173] 이때, 메모리(170)는 필요에 따라 학습된 모델을 학습 시점 또는 학습 진척도 등에 따라 복수의 버전으로 구분하여 저장할 수 있다.

[174] 이때, 메모리(170)는 입력부(120)에서 획득한 입력 데이터, 모델 학습을 위하여 이용되는 학습 데이터(또는 훈련 데이터), 모델의 학습 히스토리 등을 저장할 수 있다.

[175] 이때, 메모리(170)에 저장된 입력 데이터는 모델 학습에 적합하게 가공된 데이터뿐만 아니라, 가공되지 않은 입력 데이터 그 자체일 수 있다.

[176] 프로세서(180)는 상기 응용 프로그램과 관련된 동작 외에도, 통상적으로 단말기(100)의 전반적인 동작을 제어한다. 프로세서(180)는 위에서 살펴본 구성요소들을 통해 입력 또는 출력되는 신호, 데이터, 정보 등을 처리하거나 메모리(170)에 저장된 응용 프로그램을 구동함으로써, 사용자에게 적절한 정보 또는 기능을 제공 또는 처리할 수 있다.

[177] 또한, 프로세서(180)는 메모리(170)에 저장된 응용 프로그램을 구동하기 위하여, 도 1과 함께 살펴본 구성 요소들 중 적어도 일부를 제어할 수 있다. 나아가, 프로세서(180)는 상기 응용 프로그램의 구동을 위하여, 단말기(100)에 포함된 구성 요소들 중 적어도 둘 이상을 서로 조합하여 동작시킬 수 있다.

[178] 한편, 앞서 살펴본 것과 같이, 프로세서(180)는 응용 프로그램과 관련된 동작과, 통상적으로 단말기(100)의 전반적인 동작을 제어한다. 예를 들어, 프로세서(180)는 상기 단말기의 상태가 설정된 조건을 만족하면, 애플리케이션들에 대한 사용자의 제어 명령의 입력을 제한하는 잠금 상태를 실행하거나, 해제할 수 있다.

[179] 전원공급부(190)는 프로세서(180)의 제어 하에서, 외부의 전원, 내부의 전원을 인가 받아 단말기(100)에 포함된 각 구성요소들에 전원을 공급한다. 이러한 전원공급부(190)는 배터리를 포함하며, 상기 배터리는 내장형 배터리 또는 교체

가능한 형태의 배터리가 될 수 있다.

[180]

[181] 도 2는 본 발명의 일 실시 예에 따른 인공 신경망의 학습 장치(200)의 구성을 나타낸 블록도이다.

[182] 학습 장치(200)는 단말기(100)의 외부에 별도로 구성된 장치 또는 서버로, 단말기(100)의 러닝 프로세서(130)와 동일한 기능을 수행할 수 있다.

[183] 즉, 학습 장치(200)는 데이터 마이닝, 데이터 분석, 지능형 의사 결정 및 기계 학습 알고리즘을 위해 이용될 정보를 수신, 분류, 저장 및 출력하도록 구성될 수 있다. 여기서, 기계 학습 알고리즘은 딥 러닝 알고리즘을 포함할 수 있다.

[184] 학습 장치(200)는 적어도 하나의 단말기(100)와 통신할 수 있고, 단말기(100)를 대신하여 혹은 도와 데이터를 분석하거나 학습하여 결과를 도출할 수 있다. 여기서, 다른 장치를 도운다는 의미는 분산 처리를 통한 연산력의 분배를 의미할 수 있다.

[185] 인공 신경망의 학습 장치(200)는 인공 신경망을 학습하기 위한 다양한 장치로서, 통상적으로 서버를 의미할 수 있고, 학습 장치 또는 학습 서버 등으로 칭할 수 있다.

[186] 특히, 학습 장치(200)는 단일한 서버뿐만 아니라 복수의 서버 세트, 클라우드 서버 또는 이들의 조합 등으로 구현될 수 있다.

[187] 즉, 학습 장치(200)는 복수로 구성되어 학습 장치 세트(혹은 클라우드 서버)를 구성할 수 있고, 학습 장치 세트에 포함된 적어도 하나 이상의 학습 장치(200)는 분산 처리를 통하여 데이터 분석 또는 학습하여 결과를 도출할 수 있다.

[188] 학습 장치(200)는 주기적으로 혹은 요청에 의하여 단말기(100)에 기계 학습 또는 딥 러닝에 의하여 학습한 모델을 전송할 수 있다.

[189] 도 2를 참조하면, 학습 장치(200)는 통신부(Communication Unit, 210), 입력부(Input Unit, 220), 메모리(Memory, 230), 러닝 프로세서(Learning Processor, 240), 전원 공급부(Power Supply Unit, 250) 및 프로세서(Processor, 260) 등을 포함할 수 있다.

[190] 통신부(210)는 도 1의 무선 통신부(110) 및 인터페이스부(160)를 포괄하는 구성과 대응될 수 있다. 즉, 유무선 통신이나 인터페이스를 통하여 다른 장치와 데이터를 송수신할 수 있다.

[191] 입력부(220)는 도 1의 입력부(120)에 대응되는 구성이며, 통신부(210)를 통하여 데이터를 수신함으로써 데이터를 획득할 수도 있다.

[192] 입력부(220)는 모델 학습을 위한 훈련 데이터 및 학습된 모델(a trained model)을 이용하여 출력을 획득하기 위한 입력 데이터 등을 획득할 수 있다.

[193] 입력부(220)는 가공되지 않은 입력 데이터를 획득할 수도 있으며, 이 경우 프로세서(260)는 획득한 데이터를 전처리하여 모델 학습에 입력이 가능한 훈련 데이터 또는 전처리된 입력 데이터를 생성할 수 있다.

[194] 이때, 입력부(220)에서 수행하는 입력 데이터에 대한 전처리는, 입력

데이터로부터 입력 특징점(input feature)을 추출하는 것을 의미할 수 있다.

[195] 메모리(230)는 도 1의 메모리(170)에 대응되는 구성이다.

[196] 메모리(230)는 모델 저장부(231) 및 데이터베이스(232) 등을 포함할 수 있다.

[197] 모델 저장부(231)는 러닝 프로세서(240)을 통하여 학습 중인 또는 학습된 모델(또는 인공 신경망, 231a)을 저장하며, 학습을 통하여 모델이 업데이트되면 업데이트 된 모델을 저장한다.

[198] 이때, 모델 저장부(231)는 필요에 따라 학습된 모델을 학습 시점 또는 학습 진척도 등에 따라 복수의 버전으로 구분하여 저장할 수 있다.

[199] 도 2에 도시된 인공 신경망(231a)은 복수의 은닉층을 포함하는 인공 신경망의 하나의 예시일 뿐이며, 본 발명의 인공 신경망이 이에 한정되는 것은 아니다

[200] 인공 신경망(231a)은 하드웨어, 소프트웨어 또는 하드웨어와 소프트웨어의 조합으로 구현될 수 있다. 인공 신경망(231a)의 일부 또는 전부가 소프트웨어로 구현되는 경우, 인공 신경망(231a)을 구성하는 하나 이상의 명령어는 메모리(230)에 저장될 수 있다.

[201] 데이터베이스(232)는 입력부(220)에서 획득한 입력 데이터, 모델 학습을 위하여 이용되는 학습 데이터(또는 훈련 데이터), 모델의 학습 히스토리 등을 저장한다.

[202] 데이터베이스(232)에 저장된 입력 데이터는 모델 학습에 적합하게 가공된 데이터뿐만 아니라, 가공되지 않은 입력 데이터 그 자체일 수 있다.

[203] 러닝 프로세서(240)는 도 1의 러닝 프로세서(130)에 대응되는 구성이다.

[204] 러닝 프로세서(240)는 훈련 데이터 또는 트레이닝 셋(training set)을 이용하여 인공 신경망(231a)을 훈련(training, 또는 학습)시킬 수 있다.

[205] 러닝 프로세서(240)는 프로세서(260)가 입력부(220)를 통해 획득한 입력 데이터를 전처리한 데이터를 바로 획득하여 인공 신경망(231a)을 학습하거나, 데이터베이스(232)에 저장된 전처리된 입력 데이터를 획득하여 인공 신경망(231a)을 학습할 수 있다.

[206] 구체적으로, 러닝 프로세서(240)는 앞서 설명한 다양한 학습 기법을 이용하여 인공 신경망(231a)을 반복적으로 학습시킴으로써, 인공 신경망(231a)의 최적화된 모델 파라미터들을 결정할 수 있다

[207] 본 명세서에서는 훈련 데이터를 이용하여 학습됨으로써 파라미터가 결정된 인공 신경망을 학습 모델 또는 학습된 모델(a trained model)이라 칭할 수 있다.

[208] 이때, 학습 모델은 인공 신경망의 학습 장치(200)에 탑재된 상태에서 결과 값을 추론할 수도 있으며, 통신부(210)를 통해 단말기(100)와 같은 다른 장치에 전송되어 탑재될 수도 있다.

[209] 또한, 학습 모델이 업데이트되는 경우, 업데이트된 학습 모델은 통신부(210)를 통해 단말기(100)와 같은 다른 장치에 전송되어 탑재될 수 있다.

[210] 전원 공급부(250)는 도 1의 전원 공급부(190)에 대응되는 구성이다.

[211] 서로 대응되는 구성에 대한 중복되는 설명은 생략한다.

[212]

[213] 도 3은 본 발명의 일 실시 예에 따른 오토 스탑 시스템 제어 방법을 나타낸 동작 흐름도이다.

[214] 도 3을 참조하면, 본 발명의 일 실시 예에 따른 오토 스탑 시스템 제어 장치(100)의 프로세서(180)는 무선 통신부(110), 입력부(120) 또는 인터페이스부(160) 중에서 적어도 하나 이상을 통하여, **교통 정보 또는 차량의 주행 정보 중에서 적어도 하나를 포함하는 입력 데이터를 획득**한다(S301).

[215] 이하에서, 무선 통신부(110)와 인터페이스부(160)를 포괄하여 통신부라 칭할 수 있다. 그리고, 입력부(120)가 인터페이스부(160)를 통하여 주행 정보를 수신하는 경우에는, 입력부(120)를 인터페이스부(160)를 포괄하는 의미로 칭할 수 있다.

[216] 여기서, 교통 정보에 관한 입력 데이터는 교통량 정보, 신호 정보, 주변 차량 정보, 주변 환경 정보, 영상 정보(비전 정보), 소리 정보 등을 포함할 수 있다.

[217] 이때, 무선 통신부(110)를 통하여 입력 데이터를 획득하는 것은, 차량에 구비된 네비게이션 장치, 블랙박스 장치 등의 장치에서 수집하여 송신하는 데이터 또는 다른 차량이나 교통 데이터 관리 장치 등에서 송신하는 데이터를 무선 통신부(110)를 통하여 수신하는 것을 의미할 수 있다.

[218] 이때, 입력부(120)는 인터페이스부(160)를 통하여 차량의 ECU로부터 주행 정보를 획득할 수 있다.

[219] 이때, 프로세서(180)는 연속적으로 혹은 주기적으로 차량의 주행 정보를 획득할 수 있다.

[220] 이때, 주행 정보는 수집된 시간 정보(타임 스탬프)가 포함될 수 있다. 따라서, 차량의 주행 정보는 주행 패턴에 대한 정보를 포함한다.

[221] 여기서, 교통 데이터 관리 장치는 교통 관련 데이터를 처리하는 교통 데이터 서버 또는 네비게이션 서버 등을 포함할 수도 있고, 통신 기능을 구비하여 교통 관련 데이터를 다른 장치와 통신하는 신호등, 신호 제어기, 비콘 등의 다양한 구조물을 포함할 수 있다.

[222] 예컨대, 통신 기능을 구비한 신호등(스마트 신호등)이 도로 위의 차량 정보를 수집하여 근처의 차량들에 교통량 정보를 전송하거나, 신호 변경 정보 등을 전송하는 경우에 있어서, 상기 교통 데이터 관리 장치는 이러한 신호등을 의미할 수 있다.

[223] 이때, 인터페이스부(160)를 통하여 입력 데이터를 획득하는 것은, 차량에 구비된 네비게이션 장치, 블랙박스 장치 등의 장치에서 수집된 데이터를 인터페이스부(160)를 통하여 수신하는 것을 의미할 수 있다.

[224] 이때, 무선 통신부(110) 또는 인터페이스부(160)를 통하여 획득하는 주변 차량 정보는 주변의 다른 차량이 직접 전송한 차량 정보를 의미할 수 있다.

[225] 이때, 프로세서(180)는 무선 통신부(110)를 통한 차량 간 통신으로 직접 주변의 다른 차량으로부터 차량 정보를 수신하거나, 인터페이스부(160)를 통하여

연결된 네비게이션 장치 등이 주변의 다른 차량으로부터 수신한 차량 정보를 연결된 네비게이션 장치 등으로부터 획득할 수 있다.

[226] 즉, 프로세서(180)는 무선 통신부(110)를 이용한 차량 간 통신으로 다른 차량으로부터 차량 정보를 획득할 수도 있고, 교통 데이터 관리 장치가 직접 수집한 다른 차량들에 대한 차량 정보 또는 다른 차량들로부터 수집한 차량 정보를 무선 통신부(110)를 이용하여 교통 데이터 관리 장치로부터 획득할 수도 있다.

[227] 이때, 입력부(120)는 카메라(121)를 통하여 차량 주변의 영상 정보를 획득할 수 있고, 마이크로폰(122)를 통하여 차량 주변의 소리 정보를 획득할 수 있다.

[228] 카메라(121)는 필요에 따라 차량 전방, 후방 또는 측면 중에서 적어도 하나 이상의 영상 정보를 획득하도록 적어도 하나 이상이 구비될 수 있다. 예컨대, 차량 전방을 비추는 전방 카메라와 차량 후방을 비추는 후방 카메라가 구비될 수도 있고, 360도 전 방위를 비추는 파노라마 카메라가 구비될 수도 있다.

[229] 특히, 카메라(121)는 가시광선 영역 센서뿐만 아니라 적외선 영역 센서를 포함하여, 가시광선 영상 정보뿐만 아니라 적외선 영상 정보도 획득할 수 있다.

[230] 프로세서(180)는 주간에는 가시광선 영상 정보를 이용하고, 야간에는 적외선 영상 정보를 이용할 수 있으나, 주간과 야간 구분 없이 두 영상 정보를 모두 이용할 수도 있다. 예컨대, 두 영상 정보로부터 획득한 정보를 모두 취합하거나, 두 영상 정보 중에서 신뢰도가 높게 평가되는 영상 정보로부터 획득한 정보만을 이용할 수도 있다.

[231] 카메라(121)는 깊이 센서를 포함하여, 깊이 정보를 포함하는 영상 정보를 획득할 수 있다.

[232] 마이크로폰(121)은 가청 주파수 범위의 소리 정보뿐만 아니라 비가청 주파수 범위의 소리 정보를 획득할 수 있다. 예컨대, 비가청 주파수 범위의 소리 정보에는 초음파가 포함될 수 있다.

[233] 수집된 영상 정보와 소리 정보는 교통량 정보, 신호 정보 및 주변 환경 정보를 획득하는데 이용될 수 있으며, 주변 환경 정보에는 주변 개체의 숫자, 주변 개체의 종류, 주변 개체의 위치, 주변 개체의 움직임 정보 등이 포함될 수 있다.

[234] 주변 개체의 움직임 정보는 소리 정보의 도플러 효과를 분석하여 획득하거나, 영상 정보의 깊이 정보를 분석하여 획득할 수 있다.

[235] 이때, 교통량 정보, 신호 정보, 주변 차량 정보, 주변 교통량 정보 등은 다른 장치들로부터 가공된 상태로 획득할 수도 있지만, 상기 수집한 영상 정보 또는 소리 정보 중에서 적어도 하나 이상을 분석하여 획득할 수도 있다.

[236] 예컨대, 프로세서(180)는 영상 정보 또는 소리 정보 중에서 적어도 하나 이상을 분석하여 주변 차량의 숫자, 주변 차량의 위치, 주변 차량의 움직임, 주변 차량의 운행 상태(e.g. 브레이크등 점등 여부, 방향지시등 점등 여부, 비상등 점등 여부), 주변 신호등의 점등 상태, 주변 개체의 숫자, 주변 개체의 위치, 주변 개체의 움직임 등에 관한 정보를 획득할 수 있다.

[237] 오토 스탑 시스템 제어 장치(100)의 프로세서(180)는, **입력 데이터로부터 오토 스탑 시스템의 제어의 판단에 이용되는 기반 데이터를 획득**한다(S303).

[238] 기반 데이터는 오토 스탑 시스템의 활성화 여부를 판단하는데 이용되는 데이터로, 이는 수집된 입력 데이터에서 가공된 데이터이다. 즉, 기반 데이터는 주행 정보 중에서 수치화되지 않은 값이 미리 정해진 기준에 따라 수치화되고, 수치화된 값은 필요한 경우 정규화(normalize)되어, 분석에 용이하게 전처리된 데이터이다.

[239] 이때, 기반 데이터를 획득하는 과정은 인공 신경망 모델에서 입력 특징 벡터(input feature vector)를 추출하는 과정을 의미할 수 있다.

[240] 이때, 기반 데이터는 구간별 정체도, 구간별 신호 정보 및 주변 환경 정보 등을 포함할 수 있다.

[241] 이때, 구간별 정체도는 미리 나누어진 정체도 단계 정보로 표현될 수 있고, 연속적인 정체도 값으로 표현될 수도 있다.

[242] 예컨대, 정체도는 "정체", "서행" 및 "원활"과 같은 3단계로 구분되어 표현될 수도 있고, 0부터 100 사이의 값으로 표현될 수도 있다. 나아가, "정체", "서행" 및 "원활"과 같은 라벨에 대하여도 대표하는 값으로 표현될 수 있다. 예컨대, "정체"는 "100", "서행"은 "50", 그리고 "원활"은 "0"과 같은 대표 값으로써 표현될 수 있다.

[243] 이때, 정체도는 0부터 1 사이로 정규화(normalize)된 값으로 표현될 수 있다. 예컨대, "정체"는 "1", "서행"은 "0.5", 그리고 "원활"은 "0"과 같은 대표 값으로써 표현될 수 있다.

[244] 이때, 신호 정보는 신호등에 대한 신호 점등 정보 및 신호 스케줄 정보 중에서 적어도 하나 이상을 의미할 수 있다.

[245] 예컨대, 신호 정보는 현재 주행중인 구간에 포함된 제일 가까운 신호등의 현재 초록 불 점등 여부, 몇 초 뒤에 점등 상태가 변화하는지 또는 몇 초 뒤에 빨간 불이 점등되는지로 표현될 수 있다. 초록 불 점등 여부는 점등시 "1", 소등시 "0"으로 표현될 수 있고, 점등 상태의 변화 시간은 현재 점등된 신호의 잔여 시간을 초 단위로 표현될 수 있다.

[246] 이때, 주변 환경 정보에는 현재 차량 주변의 다른 개체의 숫자, 위치, 움직임 정보 등이 포함될 수 있다.

[247] 예컨대, 기반 데이터에 포함되는 주변 환경 정보는 전방에 가장 가까운 차량의 위치, 거리, 속도, 브레이크등 점등 여부 등으로 표현될 수 있다.

[248] 또한, 기반 데이터는 브레이크 정보에 상응하는 브레이크 페달의 입력 강도(또는 입력의 정도), 입력 횟수, 입력 간격, 입력 강도의 변화도, 이전 시점의 입력 강도 및 반복 정도 등을 포함할 수 있다. 또한, 기반 데이터는 차량의 속도 정보에 상응하는 차량의 현재 속도, 구간 속도, 속도 추이, 이전 시점의 속도 및 감속 정도 등을 포함할 수 있다.

[249] 이때, 브레이크 페달의 입력 강도는 현재(또는, 주행 정보를 수집한 시점) 입력

강도를 의미할 수 있으며, 입력 강도는 0부터 1사이의 값과 같이 미리 정해진 구간(예컨대, 0부터 1까지) 이내의 값을 갖도록 수치화하여 표현될 수 있다.

[250] 또한, 브레이크 페달의 입력 강도는 도 6에 도시된 것과 같이, 브레이크 페달의 입력에 대한 페달 유격 구간(603), 미세 제동 구간(604) 또는 급 제동 구간(605)의 해당 여부를 나타내는 페달 구간 정보를 더 포함할 수 있으며, 이 또한 미리 정해진 수치로 표현될 수 있다. 예컨대, 페달 구간 정보는 페달 유격 구간에 대해서는 0, 미세 제동 구간은 0.5, 급 제동 구간은 1과 같이 미리 정해진 기준에 따라 수치로 표현될 수 있다.

[251] 이때, 브레이크 페달의 입력 횟수는 미리 정해진 기간(예컨대, 10초 등) 동안의 브레이크 페달의 입력 횟수를 의미할 수 있다.

[252] 이때, 브레이크 페달의 입력 간격은 이전 브레이크 페달의 입력과 현재 브레이크 페달의 입력 사이의 시간적 간격을 의미할 수 있으며, 초 단위로 표현될 수 있다.

[253] 이때, 브레이크 페달의 입력 횟수나 입력 간격을 판단할 때의 1회의 입력은 브레이크 페달의 입력이 시작된 이후 완전히 입력이 종료된 기간까지를 의미할 수도 있고, 브레이크 페달의 입력 강도가 증가하다가 연속적으로 감소하는 기간까지를 의미할 수도 있다.

[254] 예컨대, 브레이크 페달의 입력 강도를 0에서 1까지라고 가정하고, 브레이크 페달의 입력이 강도가 0에서 0.5으로 증가하다가, 0.3으로 감소하고, 다시 0.6까지 증가하다가, 0으로 감소하는 경우를 고려하면; 이를 입력 강도가 0에서 0까지인 구간은 1개뿐이므로 1회의 입력으로 판단할 수도 있고, 입력 강도가 증가하다가 감소하는 구간이 2개이므로 2회의 입력으로 판단할 수도 있다.

[255] 이때, 브레이크 페달의 입력 강도의 변화도는 현재 시점으로부터 미리 정해진 이전 시점(예컨대, 0.1초 이전 등)의 입력 강도를 고려한 입력 강도의 변화도를 의미할 수 있다.

[256] 이때, 브레이크 페달의 이전 시점의 입력 강도는 미리 정해진 이전 시점(예컨대, 0.1초 이전 등)의 입력 강도를 의미할 수 있다. 또한, 브레이크 페달의 이전 시점의 입력 강도는 단일한 이전 시점의 입력 강도뿐만 아니라, 복수의 이전 시점(예컨대, 0.1초 이전, 0.2초 이전 및 0.3초 이전 등)의 입력 강도를 의미할 수 있다.

[257] 이때, 차량의 현재 속도는 현재(또는, 주행 정보를 수집한 시점) 입력 강도를 의미할 수 있으며, km/h와 같은 속도의 단위로 표현될 수 있다.

[258] 이때, 차량의 구간 속도는 미리 정해진 시간(예컨대, 10초 등) 동안의 또는 미리 정해진 구간(예컨대, 100m 등) 동안의 차량의 평균 속도를 의미할 수 있으며, km/h와 같은 속도의 단위로 표현될 수 있다.

[259] 이때, 차량의 속도 추이는 현재 시점으로부터 미리 정해진 이전 시점(예컨대, 0.1초 이전 등)의 차량의 속도를 고려한 차량 속도의 변화도를 의미할 수 있다.

[260] 이때, 차량의 이전 시점의 속도는 미리 정해진 이전 시점(예컨대, 0.1초 이전

등)의 차량의 속도를 의미할 수 있으며, km/h와 같은 속도의 단위로 표현될 수 있다. 또한, 차량의 이전 시점의 속도는 단일한 이전 시점의 속도뿐만 아니라, 복수의 이전 시점(예컨대, 0.1초 이전, 0.2초 이전 및 0.3초 이전 등)의 속도를 의미할 수 있다.

[261] 이때, 기반 데이터는 각 구간 또는 기간에 대한 정보를 포함할 수 있다. 예컨대, 기반 데이터는 브레이크 페달의 입력 횟수에 대한 미리 정해진 기간은 10초이고 브레이크 페달의 입력 강도의 변화도에서 고려하는 이전 시점은 0.1초 이전이라는 정보 등을 포함할 수 있다.

[262] 또한, 기반 데이터는 교통량 정보에 상응하는 구간 설정 기준, 구간별 정체도, 신호 정보, 주변 환경 정보 등을 포함할 수 있다.

[263] 이때, 기반 데이터에 포함되는 교통량 정보의 대상이 되는 구간은 현재 위치로부터 현재 동선에서 미리 설정된 거리만큼(예컨대, 50미터, 100미터 등)의 구간이거나, 현재 위치로부터 현재 미리 설정된 개수만큼(예컨대, 1개, 2개 등)의 신호등까지의 구간일 수 있다. 즉, 교통량 정보의 대상이 되는 구간은 현재 위치에서부터 동선 상의 100미터까지의 구간이거나 현재 위치에서부터 바로 다음 신호등까지의 구간 등일 수 있다.

[264] 이때, 기반 데이터에 포함되는 교통량 정보는 복수의 구간에 상응하는 교통량 정보들로 구성될 수 있다. 즉, 기반 데이터는 2개 이상의 구간들에 대하여 각각의 교통량 정보를 포함할 수 있다.

[265] 예컨대, 제1 구간은 현재 위치로부터 동선 상의 전방 50미터(또는, 직후 신호등)까지의 구간이고, 제2 구간은 동선 상의 전방 50미터(또는, 직후 신호등)부터 동선 상의 전방 100미터(또는, 그 다음 신호등)까지의 구간이라 가정하면, 기반 데이터에는 제1 구간에 상응하는 교통량 정보와 제2 구간에 상응하는 교통량 정보가 포함될 수 있다.

[266] 이때, 기반 데이터는 각 구간이 어떠한 기준으로 설정되었는지에 대한 정보를 포함할 수 있다.

[267] 예컨대, 거리를 기준으로 구간을 나누었는지, 또는 신호등의 위치를 기준으로 구간을 나누었는지를 나타내는 정보가 기반 데이터에 포함될 수 있다.

[268] 이때, 기반 데이터는 각 구간을 신호등의 위치를 기준으로 나누는 경우라고 하더라도, 해당 신호등까지의 거리 정보를 획득하여 구간의 거리 정보로써 대신하여 포함할 수 있다.

[269] 예컨대, 기반 데이터는 거리를 기준으로 구간을 나누는 경우 특정 구간의 거리 정보를 포함하고, 신호등의 위치를 기준으로 구간을 나누는 경우에도 대상 신호등의 위치까지의 거리 정보를 포함할 수 있으며, 이에 따라 다양한 기준으로 구간을 설정하는 경우에 있어서도 동일한 단위의 기반 데이터를 설정할 수 있는 장점이 있다.

[270] 이때, 구간별 정체도는 미리 나누어진 정체도 단계 정보로 표현될 수 있고, 연속적인 정체도 값으로 표현될 수도 있다.

[271] 예컨대, 정체도는 "정체", "서행" 및 "원활"과 같은 3단계로 구분되어 표현될 수도 있고, 0부터 100 사이의 값으로 표현될 수도 있다. 나아가, "정체", "서행" 및 "원활"과 같은 라벨에 대하여도 대표하는 값으로 표현될 수 있다. 예컨대, "정체"는 "100", "서행"은 "50", 그리고 "원활"은 "0"과 같은 대표 값으로써 표현될 수 있다.

[272] 이때, 정체도는 0부터 1 사이로 정규화(normalize)된 값으로 표현될 수 있다. 예컨대, "정체"는 "1", "서행"은 "0.5", 그리고 "원활"은 "0"과 같은 대표 값으로써 표현될 수 있다.

[273] 이때, 신호 정보는 신호등에 대한 신호 점등 정보 및 신호 스케줄 정보 중에서 적어도 하나 이상을 의미할 수 있다.

[274] 예컨대, 신호 정보는 현재 주행중인 구간에 포함된 제일 가까운 신호등의 현재 초록 불 점등 여부, 몇 초 뒤에 점등 상태가 변화하는지 또는 몇 초 뒤에 빨간 불이 점등되는지로 표현될 수 있다. 초록 불 점등 여부는 점등시 "1", 소등시 "0"으로 표현될 수 있고, 점등 상태의 변화 시간은 현재 점등된 신호의 잔여 시간을 초 단위로 표현될 수 있다.

[275] 이때, 주변 환경 정보에는 현재 차량 주변의 다른 개체의 숫자, 위치, 움직임 정보 등이 포함될 수 있다.

[276] 예컨대, 기반 데이터에 포함되는 주변 환경 정보는 전방에 가장 가까운 차량의 위치, 거리, 속도, 브레이크등 점등 여부 등으로 표현될 수 있다.

[277] 하기 [표 1] 및 [표 2]는 기반 데이터의 예시를 나타내며, 각 열은 서로 독립적인 상황에 대한 기반 데이터를 나타낸다.

[278] [표1]

	기반 데이터 1	기반 데이터 2	기반 데이터 3
구간(m)	50	30	25
교통량 정보(0~1)	원활(0)	서행(0.5)	0.7
초록 불 점등 여부(0 or 1)	1	0	1
점등 잔여 시간(s)	20	10	15
앞 차량 거리(m)	40	20	15
앞 차량 브레이크등 점등 여부(0 or 1)	0	1	1
브레이크 페달 입력 강도	0.5	0.2	0.9
페달 구간 정보	0.5(미세 제동 구간)	0(페달 유격 구간)	1(급 제동 구간)
브레이크 페달 입력 횟수	3	1	2
브레이크 페달 입력 간격(s)	5	1	10
제1 이전 시점의 브레이크 페달 입력 강도	0.4	0.15	0.3
현재 속도(km/h)	35	20	60
구간 속도(km/h)	38	23	85
제1 이전 시점의 속도(km/h)	38	22	90

[279] [표2]

	기반 데이터 4	기반 데이터 5	기반 데이터 6
구간(m)	50	30	25
교통량 정보(0~1)	원활(0)	서행(0.5)	0.7
초록 불 점등 여부(0 or 1)	1	0	1
점등 잔여 시간(s)	20	10	15
앞 차량 거리(m)	40	20	15
앞 차량 브레이크등 점등 여부(0 or 1)	0	1	1
브레이크 페달 입력 강도	0.5	0.2	0.9
페달 구간 정보	0.5(미세 제동 구간)	0(페달 유격 구간)	1(급 제동 구간)
현재 속도(km/h)	35	20	60

[280] 상기 [표 1]은 데이터의 수집 시점의 교통 정보 및 차량 주행 정보뿐만 아니라 이전 시점의 교통 정보 및 차량 주행 정보를 포함하도록 구성된 기반 데이터의 예시이다. 이러한 구조의 기반 데이터는 오토 스탑 기능 제어 모델이 규칙 기반 모델이거나 일반적인 다층 신경망의 구조를 갖는 인공 신경망 기반 모델로 구성될 때 이용될 수 있다.상기 [표 2]는 데이터의 수집 시점의 교통 정보 및 차량 주행 정보만으로 구성된 기반 데이터의 예시이다. 이러한 구조의 기반 데이터는 오토 스탑 기능 제어 모델이 순환 신경망(RNN: Recurrent Neural Network)의 구조를 갖는 인공 신경망 기반 모델로 구성될 때 이용될 수 있다.

[281] 기반 데이터는 오토 스탑 시스템의 제어의 판단에 이용되기 위하여 상기 [표 1] 및 [표 2]와 같이 수치화된 값으로 가공되어 표현될 수 있다. 즉, 기반 데이터에 포함된 정보가 거리와 시간과 같이 명확히 수치로 표현되는 경우에는 미리 정해진 단위에 맞추어 표현되고(예컨대, 거리의 단위는 미터, 시간의 단위는 초), 점등 여부나 교통량과 같이 단위가 없는 경우에는 미리 정해진 기준에 맞추어 0 내지 1 사이의 값 등으로 표현될 수 있다.

[282] 오토 스탑 시스템 제어 장치(100)의 프로세서(180)는, **기반 데이터와 오토 스탑 시스템 제어 모델을 이용하여 엔진 점화 시점 또는 엔진 점화 여부를 결정**한다(S305).

[283] 이때, 엔진 점화 시점은 오토 스탑 기능이 활성화되고 차량의 정차로 인하여 엔진이 정지된 상태에 있어서, 입력 데이터의 획득 시점 또는 엔진 점화 시점의

판단 시점으로부터 얼마만큼 이후에 엔진을 점화할 것인지를 의미할 수 있다.

[284] 예컨대, 엔진 점화 시점은 입력 데이터의 획득 시점 또는 엔진 점화 시점의 판단 시점으로부터 엔진을 점화하기까지의 시간(예컨대, 3초 뒤)으로 표현될 수도 있고, 입력 데이터의 획득 시점 또는 엔진 점화 시점의 판단 시점을 고려하여 시각 정보(예컨대, pm 13:05:45)로 표현될 수도 있다.

[285] 또한, 엔진 점화 여부는 입력 데이터의 획득 시점 또는 엔진 점화 여부의 판단 시점에 엔진을 점화할 것인지 여부를 의미할 수 있다.

[286] 여기서, 엔진 점화 시점 또는 엔진 점화 여부는 차량의 정차 상태에서 오토 스탑 기능으로 인하여 엔진이 정지된 상태에 있어서, 운전자(사용자)의 브레이크 페달 또는 악셀레이터 페달에 대한 특별한 조작을 하지 않더라도 엔진을 점화하는 시점 또는 엔진의 점화 여부를 가리킨다. 따라서, 사용자가 정차 상태에서 브레이크 페달에서 발을 떼거나 악셀레이터 페달을 밟는 경우에는 차량의 전자제어장치는 결정된 엔진의 점화 시점 또는 엔진의 점화 여부와 무관하게 엔진을 점화시킬 수 있다.

[287] 이때, 오토 스탑 시스템 제어 모델은 각 차량마다 또는 각 사용자마다 구분하여 개별적으로 설정된 개인화 모델일 수 있다.

[288] 이때, 오토 스탑 시스템 제어 모델은 기반 데이터에 대한 규칙 기반(rule-based) 제어 모델 또는 기계 학습 알고리즘에 의하여 학습된 인공 신경망 기반 제어 모델 중에서 하나를 의미할 수 있다.

[289] 여기서, 인공 신경망 기반 제어 모델은 주행 정보가 의미하는 주행 패턴을 명시적으로 출력하지 않더라도, 그 학습 과정에서 주행 패턴이 반영되어 학습된다. 이는, 인공 신경망 기반 제어 모델의 학습을 위한 학습 데이터에 시간적 정보가 포함되기 때문이다.

[290] 이때, 인공 신경망 기반 제어 모델은 각 차량 또는 각 사용자마다 구분되어 개별적으로 학습된 개인화된 모델일 수 있다.

[291] 즉, 인공 신경망 기반 제어 모델은 각 차량마다 따로 학습되어, 프로세서(180)는 현재 대상 차량에 상응하는 인공 신경망 기반 제어 모델을 사용할 수 있다. 또한, 인공 신경망 기반 제어 모델은 각 사용자마다 따로 학습되어, 프로세서(180)는 현재 대상 사용자에 상응하는 인공 신경망 기반 제어 모델을 사용할 수 있다.

[292] 이때, 오토 스탑 시스템 제어 모델은 기반 데이터에 상응하는 연관 규칙(Associative Rule) 기반 제어 모델을 의미할 수 있다.

[293] 이때, 연관 규칙 기반 제어 모델은 규칙 기반 제어 모델의 하위 개념으로 파악할 수도 있으나, 별개의 개념으로 파악할 수도 있다.

[294] 이때, 규칙 기반 제어 모델, 인공 신경망 기반 제어 모델 및 연관 규칙 기반 제어 모델은 오토 스탑 시스템 제어 장치(100)의 메모리(170)에 저장될 수 있다.

[295] 이때, 메모리(170)에 저장된 인공 신경망 기반 제어 모델은 오토 스탑 시스템 제어 장치(100)의 러닝 프로세서(130)를 통하여 학습되어 저장된 것일 수도 있고, 인공 신경망의 학습 장치(200)의 러닝 프로세서(240)를 통하여 학습되어 무선

통신부(110)를 통하여 수신하여 저장된 것일 수도 있다.

[296] 이때, 프로세서(180)는 주기적으로, 설정된 업데이트 시점의 도래, 사용자의 요청, 또는 인공 신경망의 학습 장치(200)의 요청에 의하여, 인공 신경망의 학습 장치(200)에 인공 신경망 기반 제어 모델의 업데이트 정보를 요청할 수 있다. 그리고, 프로세서(180)는 인공 신경망의 학습 장치(200)에서 인공 신경망 기반 제어 모델의 업데이트 정보를 수신하여 저장부(170)에 저장할 수 있고, 갱신된 인공 신경망 기반 제어 모델을 이용하여 오토 스탑 시스템의 엔진 점화 시점 또는 엔진 점화 여부를 결정할 수 있다.

[297] 규칙 기반 제어 모델은 기반 데이터에 포함된 각 데이터 항목들에 대하여 미리 설정된 조건이나 규칙에 따라 오토 스탑 시스템의 엔진 점화 시점 또는 엔진 점화 여부를 기계적으로 결정하는 모델이다.

[298] 이때, 규칙 기반 제어 모델은 기반 데이터에 포함된 각 데이터 항목들에 대하여 미리 설정된 조건의 충족 여부에 따른 점수를 부여하고, 각 데이터 항목들의 점수를 기반으로 오토 스탑 시스템의 엔진 점화 시점 또는 엔진 점화 여부를 결정하는 모델일 수 있다.

[299] 이때, 프로세서(180)는 규칙 기반 제어 모델을 이용하여 교통량 정보에 따른 점수, 구간 거리에 따른 점수, 초록 불 점등 여부에 따른 점수, 점등 잔여 시간에 따른 점수, 앞 차량 거리에 따른 점수, 앞 차량의 브레이크 등 점등 여부에 대한 점수 중에서 적어도 하나 이상을 고려하여 오토 스탑 시스템의 엔진 점화 시점 또는 엔진 점화 여부를 결정할 수 있다.

[300] 예컨대, 프로세서(180)는 현재 교통량이 원활하여 교통량 정보에 따른 점수를 0점을 부여하고, 초록 불이 점등되어 초록 불 점등 여부에 따른 점수로 1점을 부여하고, 앞 차량 브레이크등이 점등되어 있지 않아 앞 차량 브레이크등 점등 여부에 대한 점수로 0점으로 부여할 수 있고, 이 점수들을 가중합하여 미리 설정된 기준치를 초과하는지 여부에 따라 오토 스탑 시스템의 엔진 점화 시점 또는 엔진 점화 여부를 결정할 수 있다.

[301] 여기서, 가중합된 점수가 기준치를 초과하는 경우에 오토 스탑 시스템의 엔진을 점화하지 않도록 엔진 점화 여부를 결정하고자 하는 경우에는, 교통량 정보에 따른 점수의 가중치, 초록 불 점등 여부에 따른 점수의 가중치, 앞 차량 브레이크등 점등 여부에 따른 점수의 가중치는 양수로 설정되고, 앞 차량 거리에 따른 점수의 가중치와 점등 잔여 시간에 따른 점수의 가중치는 음수로 설정될 수 있다. 하지만, 이는 하나의 예시에 불과하며, 실시하기에 따라 각 점수에 대한 가중치의 부호가 다양하게 설정될 수 있다.

[302] 연관 규칙 기반 제어 모델은 교통 정보 또는 차량의 주행 정보 중에서 적어도 하나에 상응하는 기반 데이터와 오토 스탑 시스템의 엔진 점화 시점 또는 엔진 점화 여부 사이의 상관관계를 분석하는 연관 규칙 분석 기법에 의하여 생성된 모델을 의미할 수 있다.

[303] 연관 규칙이란 데이터의 항목들 간의 조건-결과 식으로 표현되는 유용한

패턴을 말하며, 연관 규칙 분석은 사건 속에 포함된 항목간의 연관 관계를 찾아내는 방법으로, 최소 지지도 이상의 사건 지지도를 갖는 항목 집합들인 빈발 항목 집합(Frequent item set)을 찾아내는 단계와 그것들로부터 연관 규칙을 생성하는 단계로 구분될 수 있다. 본 명세서에서는 연관 규칙 분석에 대한 일반적인 설명은 생략한다.

[304] 이때, 연관 규칙은 교통 정보 또는 차량의 주행 정보 중에서 적어도 하나 이상의 항목 별 분포를 분석하고, 유형 별 동시 발생 빈도를 파악함으로써 생성될 수 있다.

[305] 이때, 연관 규칙 기반 제어 모델은 연관 규칙 분석에 따른 연관 규칙들을 의미할 수 있다.

[306] 인공 신경망 기반 제어 모델은 기반 데이터와 동일한 형식의 학습 데이터를 입력 데이터로 이용하여 대상 특징점(또는, 출력 특징점)으로써 오토 스탑 시스템의 엔진 점화 시점 또는 엔진 점화 여부를 추론하도록 학습된 인공 신경망으로 구성된 모델을 의미할 수 있다.

[307] 이때, 인공 신경망 기반 제어 모델의 학습에 이용되는 학습 데이터는 오토 스탑 시스템의 엔진 점화 시점 또는 엔진 점화 여부가 라벨링되어, 인공 신경망 기반 제어 모델은 라벨링된 학습 데이터를 이용하여 지도 학습을 통하여 학습될 수 있다.

[308] 예를 들어, 학습 데이터는 주어진 환경에 대한 정보(교통 정보 또는 주행 정보 중에서 적어도 하나 이상을 포함)와 그 환경에 있어서 적합한 오토 스탑 시스템의 엔진 점화 시점 또는 엔진 점화 여부에 대한 정보를 포함할 수 있고, 인공 신경망 기반 제어 모델은 주어진 환경에 대한 정보로부터 상기 라벨링된 오토 스탑 시스템의 엔진 점화 시점 또는 엔진 점화 여부를 정확하게 추론하는 것을 목표로 학습되는 것일 수 있다.

[309] 이 경우, 인공 신경망 기반 제어 모델의 손실 함수(loss function, cost function)는 각 학습 데이터에 상응하는 오토 스탑 시스템의 엔진 점화 시점 또는 엔진 점화 여부에 대한 라벨과 각 학습 데이터로부터 추론된 오토 스탑 시스템의 엔진 점화 시점 또는 엔진 점화 여부의 차이의 제곱 평균으로 표현될 수 있다. 그리고, 인공 신경망 기반 제어 모델은 학습을 통하여 비용 함수를 최소화하도록 인공 신경망에 포함된 모델 파라미터들이 결정될 수 있다.

[310] 즉, 인공 신경망 기반 제어 모델은 학습용 정보(교통 정보 또는 주행 정보 중에서 적어도 하나 이상을 포함)와 그에 상응하는 라벨링된 엔진 점화 시점 또는 엔진 점화 여부가 포함된 학습 데이터를 이용하여 지도 학습된 인공 신경망 모델이고, 학습용 정보에서 입력 특징 벡터가 추출되어 입력되면 엔진 점화 시점 또는 엔진 점화 여부에 대한 결정 결과가 대상 특징 벡터로서 출력되고, 출력된 대상 특징 벡터와 학습 데이터의 라벨과의 차이에 상응하는 손실 함수를 최소화하도록 학습되는 것일 수 있다.

[311] 이때, 인공 신경망 기반 제어 모델의 대상 특징점은 오토 스탑 시스템의 엔진

점화 시점 또는 엔진 점화 여부를 나타내는 단일한 노드의 출력층으로 구성될 수 있으며, 대상 특징점은 엔진 점화 여부 중에서 엔진을 점화하는 경우를 나타낼 때에 그 값으로 "1", 그리고 엔진을 점화하지 않는 경우를 나타낼 때에 그 값으로 "0"을 가질 수 있다. 이 경우, 인공 신경망 기반 제어 모델의 출력층은 활성 함수로 시그모이드, 하이퍼볼릭 탄젠트(tanh) 등을 이용할 수 있다.

[312] 하기 [표 3] 및 [표 4]는 인공 신경망 기반 제어 모델의 학습에 이용되는 학습 데이터의 예시를 나타낸다.

[313] [표3]

	학습 데이터 1	학습 데이터 2	학습 데이터 3
구간(m)	50	30	25
교통량 정보(0~1)	원활(0)	서행(0.5)	0.7
초록 불 점등 여부(0 or 1)	1	0	1
점등 잔여 시간(s)	20	10	15
앞 차량 거리(m)	40	20	15
앞 차량 브레이크등 점등 여부(0 or 1)	0	1	0
브레이크 페달 입력 강도	0.5	0.9	0.9
페달 구간 정보	0.5(미세 제동 구간)	1(급 제동 구간)	1(급 제동 구간)
현재 속도(km/h)	0	0	10
엔진 점화 시점(s)	0	10	7

[314] [표4]

	학습 데이터 4	학습 데이터 5	학습 데이터 6
구간(m)	50	30	25
교통량 정보(0~1)	원활(0)	서행(0.5)	0.7
초록 불 점등 여부(0 or 1)	1	0	1
점등 잔여 시간(s)	20	10	15
앞 차량 거리(m)	40	20	15
앞 차량 브레이크등 점등 여부(0 or 1)	0	1	0
브레이크 페달 입력 강도	0.5	0.9	0.9
페달 구간 정보	0.5(미세 제동 구간)	1(급 제동 구간)	1(급 제동 구간)
현재 속도(km/h)	0	0	10
엔진 점화 여부(0 or 1)	1	0	0

[315] 상기 [표 3]은 라벨이 엔진 점화 시점인 학습 데이터의 예시를 나타내고 있으며, 상기 [표 4]는 라벨이 엔진 점화 여부인 학습 데이터의 예시를 나타낸다.특히, 상기 [표 3] 및 [표 4]는 각 학습 데이터가 하나의 시점에서의 교통 정보 및 주행 정보만을 포함하고 있으므로, 차량이 정지하지 않은 상태에 대하여도 학습 데이터가 포함될 수 있다.

[316] 이때, 학습 데이터에서 차량이 정지하지 않은 상태의 엔진 점화 여부는 획일적으로 0으로 설정될 수 있다. 이 경우, 차량이 정차하지 않은 경우에는 엔진을 점화하지 않아도 되기 때문에, 엔진 점화 여부는 엔진 점화를 시도하는지 여부를 의미할 수 있다.

[317] 또한, 학습 데이터에 있어서, 차량이 정차하지 않은 상태일 때의 엔진 점화 시점은 시계열적으로 누적된 학습 데이터로부터 획득할 수 있으며, 이는 해당 정차하지 않은 상태의 학습 데이터가 수집된 시점 이후에 차량이 정차하였다가 엔진이 점화되는 시점을 의미할 수 있다.

[318] 이때, 프로세서(180)는 기반 데이터를 인공 신경망 기반 제어 모델에 입력하고, 인공 신경망 기반 제어 모델을 이용하여 입력된 기반 데이터로부터 오토 스탑 시스템의 엔진 점화 시점 또는 엔진 점화 여부를 가리키는 대상 특징점을 획득하며, 획득한 대상 특징점에 따라 오토 스탑 시스템의 엔진 점화 여부를

결정할 수 있다.

[319] 이때, 프로세서(180)는 기반 데이터를 인공 신경망 기반 제어 모델에 입력하는 과정에서, 기반 데이터로부터 인공 신경망 기반 제어 모델의 입력에 적합한 입력 특징 벡터를 추출할 수 있다. 하지만, 단계(S303)에서 획득한 기반 데이터가 사실상 인공 신경망 기반 제어 모델의 입력 데이터로써 사용하기 위하여 추출한 특징 벡터를 의미하므로, 별도의 특징 벡터를 추출하는 과정을 거치지 않을 수 있다.

[320] 즉, 단계(S303)에서 기반 데이터를 획득할 때에 수치화되지 않은 정보는 수치화하여 표현하고, 수치화된 정보를 정규화하여 나타내는 과정은, 인공 신경망 기반 제어 모델의 입력 데이터로써 이용하기 위한 특징점 추출 과정이라 볼 수 있다.

[321] 오토 스탑 시스템 제어 장치(100)의 프로세서(180)는, **결정된 엔진 점화 시점이 도래하였는지 또는 결정된 엔진 점화 여부가 점화인지 판단**한다(S307).

[322] 단계(S307)의 판단 결과, **결정된 엔진 점화 시점이 도래하였거나 결정된 엔진 점화 여부가 점화인 경우, 프로세서(180)는 엔진을 점화**하고(S309), 엔진 점화 정보를 출력한다(S311).

[323] 엔진을 점화한다는 것의 의미는, 오토 스탑 시스템으로 인하여 차량의 정차시에 자동으로 엔진이 정지한 상태에서 엔진을 점화하는 것을 의미한다.

[324] 이때, 프로세서(180)가 차량의 전자제어유닛인 경우에는, 프로세서(180)는 직접 엔진을 점화하도록 제어할 수 있다.

[325] 이때, 프로세서(180)가 차량의 전자제어유닛과 별개로 구성된 경우에는, 프로세서(180)는 무선 통신부(110) 또는 인터페이스부(160)를 통하여 차량의 전자제어유닛에 엔진을 점화하는 제어 신호를 전송할 수 있다.

[326] 이때, 프로세서(180)는 출력부(150)를 통하여 엔진 점화 정보를 출력할 수 있다.

[327] 엔진 점화 정보는 사용자가 엔진을 점화하기 위하여 브레이크 페달에서 발을 떼거나 악셀레이터 페달을 밟는 것과 같은 행동을 하지 않더라도, 오토 스탑 시스템 제어 모델의 판단 결과에 따라 엔진이 점화되었음을 알리는 정보를 포함할 수 있다.

[328] 예컨대, 프로세서(180)는 디스플레이부(151)를 제어하여 엔진이 자동으로 점화되었음을 시각화하여 메시지나 아이콘 등으로 출력할 수 있다. 또한, 프로세서(180)는 음향 출력부(152)를 제어하여 엔진이 자동으로 점화되었음을 알리는 정보를 청각화하여 음성이나 경고음 등으로 출력할 수 있다. 여기서, 음성은 미리 녹음된 안내 음성이나 기계적으로 합성된 음성 등이 포함될 수 있다.

[329] 또한, 엔진 점화 정보는 엔진이 자동으로 점화된 것에 대한 만족도나 평가를 요청하는 알림을 포함할 수 있다.

[330] 단계(S307)의 판단 결과, 결정된 엔진 점화 시점이 도래하지 않았거나 결정된 엔진 점화 여부가 점화가 아닌 경우, 프로세서(180)는 별도의 동작을 하지

않는다.

[331] 이때, 프로세서(180)는 입력부(120)를 통하여 사용자의 결정된 엔진 점화 시점에 대한 피드백 정보를 획득할 수 있다.

[332] 이때, 프로세서(180)는 사용자가 의도적으로 결정된 엔진 점화 시점에 대한 피드백 음성을 발화하거나, 피드백 버튼을 눌러서 피드백 정보를 제공하는 경우뿐만 아니라, 사용자가 무의식적으로 결정된 엔진 점화 시점에 대하여 나타내는 반응을 피드백 정보로 획득할 수 있다.

[333] 예컨대, 사용자가 피드백을 위하여 의도적으로 발화한 "점화가 너무 느린데"와 같은 음성, 터치 가능한 디스플레이나 버튼을 통하여 입력한 엔진 점화 시점에 대한 평가 정보, 사용자가 무의식적으로 발화한 불만의 음성(탄식)이나 만족의 음성(탄성) 등이 피드백 정보로써 수집될 수 있다.

[334] 이때, 수집된 피드백 정보는 규칙 기반 제어 모델 또는 인공 신경망 기반 제어 모델을 갱신하는데 이용될 수 있다.

[335] 이때, 수집된 피드백 정보는 엔진 점화 시점 또는 엔진 점화 여부에 대한 라벨링 정보로써 이용될 수 있다.

[336] 이때, 프로세서(180)는 피드백 정보와 상기 피드백 정보에 상응하는 기반 데이터를 쌍으로 메모리(170)에 저장할 수 있다.

[337] 이때, 저장된 기반 데이터 및 피드백 정보 쌍은 러닝 프로세서(130) 또는 인공 신경망의 학습 장치(200)의 러닝 프로세서(240)를 통하여 인공 신경망 기반 제어 모델을 업데이트하는데 이용될 수 있다.

[338] 이와 같이, 사용자의 만족도 또는 선호도를 반영하여 갱신된 오토 스탑 시스템 제어 모델을 이용하여 엔진 점화 시점 또는 엔진 점화 여부를 결정함으로써, 사용자별로 만족도가 높은 개별화된 오토 스탑 시스템의 제어가 가능하다.

[339] 또한, 프로세서(180)는 차량이 주행할 때 수집되는 입력 데이터에 대하여 엔진 점화 시점 또는 엔진 점화 여부에 대한 라벨을 추가하여 갱신용 학습 데이터를 생성할 수 있다.

[340] 구체적으로, 프로세서(180)는 미리 정해진 주기마다(예컨대, 1초마다) 또는 실시간으로 입력 데이터를 획득할 수 있는데, 입력 데이터의 수집 시점 당시에는 엔진 점화 시점 또는 엔진 점화 여부를 판단하지 못하는 경우가 많다. 하지만, 프로세서(180)는 특정 입력 데이터의 엔진 점화 시점 또는 엔진 점화 여부에 대한 라벨을 해당 입력 데이터의 수집 시점 이후에 최초로 차량을 다시 주행시키기 위한 제어가 수행되는 시점 정보를 고려하여 결정할 수 있다.

[341] 예컨대, 하기 [표 5]와 같이 입력 데이터가 수집되는 경우를 가정하면, 프로세서(180)는 하기 [표 6]과 같은 갱신용 학습 데이터를 생성할 수 있다. 하기 [표 5] 및 [표 6]은 갱신용 학습 데이터를 생성하는 방법의 예시를 나타내기 위하여 입력 데이터에 포함되는 정보를 차량의 현재 속도와 브레이크 페달의 입력만으로 한정하여 나타내었지만, 본 발명이 이에 한정되는 것은 아니다.

[342] [표5]

입력 데이터	수집 시점	현재 속도(km/h)	브레이크 페달 입력 강도(0~100)
데이터 1	15:00:00	5	30
데이터 2	15:00:01	0	80
데이터 3	15:00:02	0	80
데이터 4	15:00:03	0	80
데이터 5	15:00:04	0	40
데이터 6	15:00:05	5	0
데이터 7	15:00:06	10	0
데이터 8	15:00:07	20	0
데이터 9	15:00:08	40	0

[343] [표6]

갱신용 학습 데이터	수집 시점	현재 속도(km/h)	브레이크 페달 입력 강도(0~100)	엔진 점화 시점(s)
데이터 1	15:00:00	5	30	4
데이터 2	15:00:01	0	80	3
데이터 3	15:00:02	0	80	2
데이터 4	15:00:03	0	80	1
데이터 5	15:00:04	0	80	0
데이터 6	15:00:05	0	40	0
데이터 7	15:00:06	5	0	(미정)
데이터 8	15:00:07	10	0	(미정)
데이터 9	15:00:08	30	0	(미정)

[344] 상기 [표 5] 및 [표 6]을 참조하면 입력 데이터는 매 1초마다 수집되었으며, 수집된 입력 데이터에 따르면 15:00:01에 차량이 정지하였으며, 15:00:04부터(또는 15:00:05부터) 차량을 다시 주행시키기 위한 제어로써 브레이크 페달의 입력이 감소하기 시작하였으며, 15:00:06부터 차량이 다시 주행하기 시작하였다. 프로세서(180)는 각 입력 데이터에 대하여 수집된 시점 이후에 최초로 차량을 다시 주행시키기 위한 제어가 수행되는 시점을 찾으며, 그 찾은 시점 정보를 고려하여 엔진 점화 시점을 결정하게 된다. 따라서,

15:00:00부터 15:00:04 사이에 수집된 입력 데이터 1 내지 입력 데이터 5에 대하여는, 15:00:04가 최초로 차량을 다시 주행시키기 위한 제어가 수행되므로, 프로세서(180)는 입력 데이터 1 내지 5에 대하여 15:00:04를 기준으로 엔진 점화 시점(또는, 엔진 점화 여부)을 결정할 수 있다. 그리고, 입력 데이터 6은 15:00:05에 수집되어 차량을 다시 주행시키기 위한 제어가 수행되는 도중이므로, 프로세서(180)는 입력 데이터 6에 대하여 여전히 15:00:04를 기준으로 엔진 점화 시점(또는, 엔진 점화 여부)를 결정할 수 있다.

[345] 프로세서(180)는 다시 차량이 주행하기 시작하고 수집된 입력 데이터 7 내지 9에 대하여는, 이후에 최초로 다시 주행을 위한 제어가 수행되는 입력 데이터가 획득되었을 때에 해당 입력 데이터를 이용하여 엔진 점화 시점(또는, 엔진 점화 여부)를 결정할 수 있다.

[346] 이와 같이 프로세서(180)가 차량의 주행 도중에 획득되는 입력 데이터로부터 갱신용 학습 데이터를 생성하면, 오토 스탑 시스템 제어 모델은 생성된 갱신용 학습 데이터를 이용하여 갱신될 수 있으며, 이와 같이 갱신된 오토 스탑 시스템 제어 모델은 보다 높은 정확도로 엔진 점화 시점 또는 엔진 점화 여부를 결정할 수 있다.

[347] 본 발명에 따르면 사용자는 현재 주행 상황에 적합한 오토 스탑 시스템을 제공받을 수 있고, 이를 통하여 오토 스탑 시스템이 부적절한 때에 동작함에 따른 사용자의 피로도가 증가하거나, 연비가 악화되거나, 정차 후 출발이 지연되는 문제 등을 효과적으로 해결할 수 있다.

[348]

[349] 도 4는 도 3에 도시된 입력 데이터를 획득하는 단계(S301)의 일 예를 나타낸 동작 흐름도이다.

[350] 도 5 및 6은 본 발명의 일 실시 예에 따라 획득하는 입력 데이터의 예시를 나타내는 도면이다.

[351] 도 4 내지 6을 참조하면, 프로세서(180)는 무선 통신부(110), 입력부(120) 또는 인터페이스부(160) 중에서 적어도 하나 이상을 통하여, **교통량 정보(501)를 획득**한다(S401).

[352] 교통량 정보(501)는 도로의 차량 수 정보, 차량 움직임 정보, 정체도 정보, 운행 소요 시간 정보 등을 포함할 수 있다.

[353] 이때, 획득하는 교통량 정보는 현재 차량으로부터 미리 설정된 반경(예컨대, 200미터 등) 이내의 도로에 대한 교통량 정보를 의미할 수도 있고, 현재 설정된 사용자의 운전 동선상의 도로에 대한 교통량 정보를 의미할 수도 있다.

[354] 이때, 프로세서(180)는 획득한 영상 정보 또는 소리 정보 중에서 적어도 하나 이상을 분석하여 교통량 정보를 획득할 수 있다.

[355] 이때, 프로세서(180)는 네비게이션 장치/시스템으로부터 교통량 정보를 수신하여 획득할 수 있다.

[356] 프로세서(180)는 무선 통신부(110), 입력부(120) 또는 인터페이스부(160)

중에서 적어도 하나 이상을 통하여, **신호 정보(502)를 획득**한다(S403).

[357] 신호 정보(502)는 현재 신호의 점등 정보(예컨대, 빨간 불, 초록 불 등), 신호 스케줄 정보(예컨대, 현재 점등된 신호의 잔여 시간, 다음 초록 불 점등 예상 시간 등) 등을 포함할 수 있다.

[358] 이때, 프로세서(180)는 획득한 영상 정보 또는 소리 정보 중에서 적어도 하나 이상을 분석하여 신호 정보를 획득할 수 있다.

[359] 이때, 프로세서(180)는 다른 차량이나 교통 데이터 관리 장치 등으로부터 신호 정보를 획득할 수 있다.

[360] 프로세서(180)는 무선 통신부(110), 입력부(120) 또는 인터페이스부(160) 중에서 적어도 하나 이상을 통하여, **주변 환경 정보(503)를 획득**한다(S405).

[361] 주변 환경 정보(503)는 주변에 개체에 대한 정보로, 주변 개체들의 수, 위치 정보, 움직임 정보 등을 포함할 수 있다. 즉, 주변 환경 정보는 주변 차량 정보를 포함할 수 있다.

[362] 주변 차량 정보는 주변에 있는 차량들의 수, 위치 정보, 움직임 정보, 운행 정보 등을 포함할 수 있다. 여기서, 운행 정보는 주변 차량의 동선 정보, 목적지 정보, 브레이크등 점등 여부, 방향지시등 점등 여부, 비상등 점등 여부 등을 포함할 수 있다.

[363] 이때, 프로세서(180)는 획득한 영상 정보 또는 소리 정보 중에서 적어도 하나 이상을 분석하여 주변 환경 정보를 획득할 수 있다.

[364] 이때, 프로세서(180)는 다른 차량이나 교통 데이터 관리 장치 등으로부터 주변 환경 정보를 획득할 수 있다.

[365] 상술한 바와 같이 교통량 정보(501), 신호 정보(502) 및 주변 환경 정보(503)는 다양한 방법을 통하여 획득할 수 있으나, 일반적으로는 교통량 정보(501)는 네비게이션 장치/시스템으로부터 획득되고, 신호 정보(502)와 주변 환경 정보(503)는 영상 정보로부터 획득될 수 있다.

[366] 프로세서(180)는 입력부(120) 또는 인터페이스부(160) 중에서 적어도 하나 이상을 통하여, **브레이크 정보(601)를 획득**한다(S407).

[367] 이때, 프로세서(180)는 차량의 전자제어유닛으로부터 브레이크 정보를 수신할 수 있다.

[368] 이때, 브레이크 정보는 연속적으로 혹은 주기적으로 수집된 브레이크 페달의 입력 강도를 의미할 수 있다. 또한, 브레이크 정보에는 브레이크 페달의 입력 강도가 수집된 시점에 대한 시간 정보(타임 스탬프)가 포함될 수 있다.

[369] 이때, 프로세서(180)는 브레이크 정보로서 실시간으로 브레이크 페달의 입력 강도를 수신할 수 있다. 그리고, 수신된 브레이크 정보는 메모리(170)에 저장될 수 있다.

[370] 이때, 수집된 브레이크 정보는 시간대별 브레이크 페달의 입력 강도에 대한 정보를 포함하며, 추후 기반 데이터를 획득하는데 이용된다.

[371] 프로세서(180)는 입력부(120) 또는 인터페이스부(160) 중에서 적어도 하나

이상을 통하여, **속도 정보(602)를 획득**한다(S409).

[372] 이때, 프로세서(180)는 차량의 전자제어유닛이나 네비게이션 장치 등으로부터 속도 정보를 수신할 수 있다.

[373] 이때, 속도 정보는 연속적으로 혹은 주기적으로 수집된 차량의 속도를 의미할 수 있다. 또한, 속도 정보에는 차량의 속도가 수집된 시점에 대한 시간 정보(타임 스탬프)가 포함될 수 있다.

[374] 이때, 프로세서(180)는 속도 정보로서 실시간으로 차량의 속도를 수신할 수 있다. 그리고, 수신된 속도 정보는 메모리(170)에 저장될 수 있다.

[375] 이때, 수집된 속도 정보는 시간대별 차량의 속도에 대한 정보를 포함하며, 추후 기반 데이터를 획득하는데 이용된다.

[376] 선택적 실시 예에서, 입력 데이터를 획득하는 상기 단계들(S401, S403, S405, S407 및 S409)은 서로 병렬적으로 수행될 수도 있고, 서로 순서가 바뀌어 수행될 수도 있다.

[377]

[378] 도 7은 본 발명의 일 실시 예에 따른 규칙 기반 제어 모델의 예시를 나타낸 도면이다.

[379] 도 7을 참조하면, 규칙 기반 제어 모델은 교통량 정보, 신호 정보 및 앞 차량의 브레이크 등 점등 정보를 이용하여 오토 스탑 시스템의 엔진 점화 여부를 결정하는 모델일 수 있다.

[380] 예컨대, 규칙 기반 제어 모델은 교통량 정보가 "정체"인 경우에는 신호가 초록 불이고 앞 차량의 브레이크 등이 소등된 경우에만 엔진을 점화하도록 엔진 점화 여부를 결정하는 모델일 수 있다. 그리고, 규칙 기반 제어 모델은 교통량 정보가 "서행"인 경우에는 신호 무관 앞 차량의 브레이크 등이 소등된 경우에 엔진을 점화하도록 엔진 점화 여부를 결정하는 모델일 수 있다. 그리고, 규칙 기반 제어 모델은 교통량 정보가 "원활"인 경우에는 신호가 초록 불일 때는 앞 차량의 브레이크 등과 무관하게 엔진을 점화하고, 신호가 빨간 불일 때는 앞 차량의 브레이크 등이 소등된 경우에만 엔진을 점화하도록 엔진 점화 여부를 결정하는 모델일 수 있다.

[381] 도 7은 엔진 점화 여부를 판단하기 위하여 교통량 정보, 신호 정보 및 앞 차량의 브레이크 등 정보를 고려하는 규칙 기반 제어 모델의 일 예를 도시하고 있을 뿐으로, 규칙 기반 제어 모델은 다양한 실시 예에 따라 동일한 정보를 이용하더라도 엔진 점화 여부를 다르게 판단하는 모델일 수 있다.

[382] 또한, 규칙 기반 제어 모델은 다양한 실시 예에 따라 엔진 점화 여부를 판단하기 위하여 교통량 정보, 신호 정보 및 앞 차량의 브레이크 등 정보에 한정되지 않은 다양한 정보들을 이용할 수 있다.

[383] 도 7에 도시된 규칙 기반 제어 모델은 엔진 점화 여부를 결정하는 제어 모델이지만, 다양한 실시 예에 따라 엔진 점화 시점을 결정하는 제어 모델일 수 있다.

[384] 예컨대, 규칙 기반 제어 모델은 교통량 정보가 "원활"이고 신호가 초록 불이고 앞 차량의 브레이크 등이 소등되면 즉시 엔진을 점화하도록 엔진 점화 시점을 0초로 결정하고, 교통량 정보가 "정체"이고 신호가 초록 불이고 앞 차량의 브레이크가 소등되면 1초 뒤에 엔진을 점화하도록 엔진 점화 시점을 1초로 결정하는 모델일 수 있다.

[385]

[386] 도 8은 본 발명의 일 실시 예에서 연관 규칙 분석에 사용되는 데이터의 형식의 예시를 나타낸 도면이다.

[387] 도 9는 본 발명의 일 실시 예에서 연관 규칙 분석에 따라 생성된 연관 규칙의 예시를 나타낸 도면이다.

[388] 도 8 및 9를 참조하면, 본 발명의 일 실시 예에서 연관 규칙 분석에 사용되는 데이터는 특정 상황에 대한 교통 정보와 그 상황에 적합한 오토 스탑 시스템의 제어 정보를 포함할 수 있다.

[389] 예컨대, 연관 규칙 분석에 사용되는 데이터에는 현재 시점의 정보와 과거 시점(제1 이전 시점 등)의 정보가 포함되며, 교통량 정보, 신호 정보, 차량 속도 또는 앞 차량 속도 중에서 적어도 하나 이상이 포함될 수 있다.

[390] 이때, 연관 규칙 분석에 이용되는 데이터는 상술한 기반 데이터를 의미할 수 있다. 따라서, 입력 데이터에 포함된 항목 중에서 수치로 표현되지 않은 항목도 수치화되어, 이산적인 대표 값들로 표현되거나(예컨대, 0, 0.5, 1 등), 연속적인 범위 내에서의 실수 값으로 표현될 수 있다.

[391] 그리고, 입력 데이터에는 교통 정보, 주행 정보, 그리고 그 상황에서의 엔진 점화 시점 또는 엔진 점화 여부에 대한 사용자 피드백이 포함될 수 있다.

[392] 사용자 피드백은 특정 상황에서의 엔진 점화 시점 또는 엔진 점화 여부에 대한 명확한 명령(예: "1초 후 엔진 점화" 또는 "엔진 비점화" 등)으로 구성될 수도 있지만, 연관 규칙 기반 제어 모델에서 결정한 엔진 점화 시점 또는 엔진 점화 여부에 대한 만족도 피드백(예: "엔진 점화가 너무 늦다" 또는 "이번 엔진 점화가 맘에 안든다" 등)으로 구성될 수도 있다.

[393] 만약, 사용자 피드백이 연관 규칙 기반 제어 모델에서 결정한 엔진 점화 시점 또는 엔진 점화 여부에 대한 만족도 피드백으로 구성되는 경우, 그 만족도 피드백의 대상이 된 엔진 점화 시점 또는 엔진 점화 여부가 사용자 피드백에 함께 포함될 수 있다.

[394] 연관 규칙 분석에 따라 생성된 연관 규칙들은 연관 규칙 기반 제어 모델이라 칭할 수 있으며, 도 9에 도시된 바와 같이 교통 정보와 그에 적합한 오토 스탑 시스템의 엔진 점화 시점 또는 엔진 점화 여부에 대한 정보의 상관관계로 나타날 수 있다.

[395]

[396] 도 10은 본 발명의 일 실시 예에 따른 인공 신경망 기반 제어 모델의 예시를 나타낸 도면이다.

[397] 도 10을 참조하면, 본 발명의 일 실시 예에 따른 오토 스탑 시스템 제어 모델은 인공 신경망 기반 제어 모델이며, 제1 학습 데이터를 이용하여 지도 학습된 다층 신경망(Multilayer Neural Network)일 수 있다. 이하에서는 이를 제1 인공 신경망 기반 제어 모델 또는 제1 모델(1002)이라 칭할 수 있다.

[398] 구체적으로, 제1 모델(1002)은 다층으로 구성된 인공 신경망으로, 교통 정보 및 주행 정보(1001)와, 그에 상응하는 라벨링된 엔진 점화 시점 또는 엔진 점화 여부(1003)가 포함된 제1 학습 데이터를 이용하여 학습된 것일 수 있다.

[399] 제1 모델(1002)은 입력층(1004)에 입력 데이터에서 추출된 입력 특징점 또는 기반 데이터가 입력되면, 하나 이상의 은닉층들(1005)을 거쳐 출력층(1006)에서 출력 특징점으로써 엔진 점화 시점 또는 엔진 점화 여부를 출력하는 모델일 수 있다.

[400] 도 10에는 입력층(1004), 은닉층(1005) 및 출력층(1006)을 하나의 원으로 간략하게 표시하였으나, 각각은 복수의 노드들을 포함할 수 있으며, 특히 은닉층(1005)은 하나 이상의 은닉층들로 구성될 수 있다.

[401] 이때, 제1 모델(1002)은 교통량 정보, 신호 정보, 차량의 주행 정보 또는 앞 차량의 주행 정보 중에서 적어도 하나가 포함된 입력 데이터 또는 기반 데이터를 입력 받을 수 있다. 그리고, 제1 모델(1002)은 현재 시점의 정보뿐만 아니라 미리 설정된 과거 시점의 정보를 포함하는 입력 데이터 또는 기반 데이터를 입력 받을 수 있다.

[402] 예컨대, 제1 모델(1002)의 입력 데이터에는 현재 교통량 정보, 제1 이전 시점의 교통량 정보, 제2 이전 시점의 교통량 정보, 현재 신호 정보, 제1 이전 시점의 신호 정보, 제2 이전 시점의 신호 정보, 현재 차량 주행 정보, 제1 이전 시점의 차량 주행 정보, 제2 이전 시점의 차량 주행 정보, 현재 앞 차량의 주행 정보, 제1 이전 시점의 앞 차량의 주행 정보 및 제2 이전 시점의 앞 차량 주행 정보가 포함될 수 있다.

[403] 여기서, 앞 차량의 주행 정보에는 앞 차량의 속도, 앞 차량의 브레이크 등 점등 여부 또는 앞 차량과의 거리 중에서 적어도 하나 이상이 포함될 수 있다.

[404] 이때, 이전 시점은 미리 설정된 이전의 시점으로, 예컨대 제1 이전 시점은 현재로부터 1초 이전이고, 제2 이전 시점은 현재로부터 5초 이전으로 설정될 수 있다.

[405] 이때, 상기 예시에서는 제1 이전 시점과 제2 이전 시점의 2개의 이전 시점 정보가 포함되어 있으나, 본 발명에 있어서 입력 데이터 또는 기반 데이터에 포함되는 이전 시점의 개수가 2개로 제한되지 않는다.

[406] 이와 같이, 입력 데이터 또는 기반 데이터 자체에 현재의 정보뿐만 아니라 이전 시점의 정보가 포함됨에 따라, 순환 신경망(Recurrent Neural Network)이 아닌 통상의 다층 신경망(Multilayer Neural Network)으로 구성된 인공 신경망 기반 제어 모델을 이용하여 현재뿐만 아니라 과거의 시점의 정보를 고려하여 엔진 점화 시점 또는 엔진 점화 여부를 결정할 수 있다.

[407]

[408] 도 11은 본 발명의 일 실시 예에 따른 인공 신경망 기반 제어 모델의 예시를 나타낸 도면이다.

[409] 도 11을 참조하면, 본 발명의 일 실시 예에 따른 오토 스탑 시스템 제어 모델은 인공 신경망 기반 제어 모델이며, 제2 학습 데이터를 이용하여 지도 학습된 순환 신경망(Recurrent Neural Network)일 수 있다. 이하에서는 이를 제2 인공 신경망 기반 제어 모델 또는 제2 모델이라 칭할 수 있다.

[410] 여기서, 순환 신경망이란 인공 신경망의 한 종류로, 도 12에 도시된 바와 같이, 은닉층의 출력이 다시 은닉층으로 입력되는 순환적인 구조를 가짐으로써 시간 연속적인 정보를 처리하는데 장점을 갖는 인공 신경망이다.

[411] 즉, 특정 시점(time step)에서 은닉층의 노드(뉴런)들은 각각 바로 이전 시점에서의 은닉층의 출력을 입력 받음에 따라, 은닉층의 노드들이 갖고 있는 값은 과거의 은닉층의 노드들의 값에 영향을 받는다. 이러한 측면에서 은닉층은 이전 시점의 값을 기억하는 메모리의 역할을 한다고 볼 수 있으며, 따라서 은닉층의 노드들을 메모리 셀(memory cell)이라 칭할 수 있다.

[412] 또한, 제2 모델(1102)는 통상적인 순환 신경망뿐만 아니라, 그로부터 파생된 LSTM(Long Short Term Memory)나 GRU(Gated Recurrent Unit) 등으로 구현될 수도 있으며, 이들에 대한 구체적인 설명은 생략한다.

[413] 구체적으로, 제2 모델은 순환 신경망(1102)으로, 교통 정보 및 주행 정보(1101)와, 그에 상응하는 라벨링된 엔진 점화 시점 또는 엔진 점화 여부(1103)가 포함된 제2 학습 데이터를 이용하여 학습된 것일 수 있다.

[414] 제2 모델(1102)의 입력층(1104)은 입력 데이터에서 추출된 입력 특징점 또는 기반 데이터를 입력 받는다.

[415] 제2 모델(1102)의 은닉층(1105)은 입력층(1104)에서 전달되는 값과 이전 시점의 은닉층(1106)에서 전달되는 값으로부터 출력을 생성하여 출력층(1107)으로 전달한다.

[416] 제2 모델(1102)의 출력층(1107)은 출력 특징점으로써 엔진 점화 시점 또는 엔진 점화 여부를 출력할 수 있다.

[417] 도 11에는 입력층(1104), 은닉층(1105 및 1106) 및 출력층(1107)을 하나의 원으로 간략하게 표시하였으나, 각각은 복수의 노드들을 포함할 수 있으며, 특히 은닉층(1105 및 1106)은 하나 이상의 은닉층들로 구성될 수 있다.

[418] 이때, 제2 모델(1102)은 교통량 정보, 신호 정보, 차량의 주행 정보 또는 앞 차량의 주행 정보 중에서 적어도 하나가 포함된 입력 데이터 또는 기반 데이터를 입력 받을 수 있다. 그리고, 제2 모델(1102)은 제1 모델(1002)과는 달리 현재 시점의 정보만을 포함하는 입력 데이터 또는 기반 데이터를 입력 받을 수 있다. 이는, 제2 모델이 순환 신경망의 구조적인 특징으로 인하여 각 시점마다 해당 시점의 데이터만을 입력하더라도 과거 시점을 고려한 시계열적인 데이터에 대한 분석이 가능한 모델이기 때문이다.

[419] 예컨대, 제2 모델(1102)의 입력 데이터에는 현재 교통량 정보, 현재 신호 정보, 현재 차량 주행 정보 및 현재 앞 차량의 주행 정보가 포함될 수 있다.

[420] 여기서, 앞 차량의 주행 정보에는 앞 차량의 속도, 앞 차량의 브레이크 등 점등 여부 또는 앞 차량과의 거리 중에서 적어도 하나 이상이 포함될 수 있다.

[421] 이와 같이, 순환 신경망으로 구성된 모델을 이용함에 따라, 연속적으로 또는 주기적으로 수집되는 교통 정보나 주행 정보를 효과적으로 분석하여 사용자에게 적합한 엔진 점화 시점 또는 엔진 점화 여부를 결정할 수 있다.

[422]

[423] 도 12는 본 발명의 일 실시 예에 따른 오토 스탑 시스템의 제어 시나리오의 예시를 도시한 도면이다.

[424] 도 12는 앞 차량의 주행 정보만을 고려하여 엔진 점화 시점 또는 엔진 점화 여부를 결정하는 오토 스탑 시스템의 제어 시나리오의 간략화된 예시를 도시하고 있다.

[425] 앞 차량(1203)이 시점 t1에 정지하면(1204), 사용자의 조작 또는 시스템의 조작에 의하여 시점 t2에 브레이크(1202)가 활성화되고(1205), 그에 따라 차량이 정지하고, 오토 스탑 시스템에 의하여 시점 t3에 엔진(1201)이 정지한다(1206).

[426] 여기서, 앞 차량이 시점 t4에 다시 출발하면(1207), 사용자의 조작 또는 시스템의 조작에 의하여 시점 t6에 브레이크가 비활성화된다고 가정한다(1209).

[427] 이 경우, 통상의 오토 스탑 시스템에서는 t4부터 t6까지의 기간(1210) 동안에는 엔진이 계속 정지된 상태로 유지되지만, 본 발명의 일 실시 예에서는 t4부터 t6까지의 기간(1210) 내의 특정 시점 t5에 엔진을 점화한다(1208). 따라서, 본 발명에 따르면 브레이크 페달을 계속하여 밟고 있는 경우라 하더라도 다시 주행할 것으로 기대할 수 있을 때에는 엔진을 점화함으로써, 주행을 바로 할 수 있는 준비를 할 수 있다.

[428] 이때, 엔진을 언제 점화할 것인지는 t4부터 t6까지의 기간(1210) 내에서 오토 스탑 시스템 제어 모델에서 결정되는 엔진 점화 여부 또는 엔진 점화 시점에 따라 결정될 수 있다.

[429] 예컨대, t4부터 t6까지의 기간(1210) 내의 어느 시점(예컨대, t7)에서 오토 스탑 시스템 제어 모델이 엔진을 점화할 것으로 결정하면, 그 시점(t7)에 엔진이 점화될 수 있다.

[430] 또는, 예컨대, t4부터 t6까지의 기간(1210) 내의 어느 시점(예컨대, t8)에서 오토 스탑 시스템 제어 모델이 엔진의 점화 시점을 0.5초 뒤로 결정하는 경우에 두 가지 방법에 따라 엔진이 점화될 수 있다. 첫 번째 방법에 따르는 경우에는 0.5초 뒤(t8+0.5초)에 엔진이 점화될 수 있다. 두 번째 방법에 따르는 경우에는 0.5초 뒤(t8+0.5초)에 다시 오토 스탑 시스템 제어 모델에서 결정된 엔진 점화 시점을 확인하고, 그 결과에 따라 엔진이 점화될지 여부가 결정될 수 있다.

[431] 프로세서(180)는 실시간으로 또는 주기적으로 오토 스탑 시스템 제어 모델을 이용하여 엔진 점화 시점을 결정할 수 있는데, 만약 특정 시점 t9에서 오토 스탑

시스템 제어 모델이 엔진 점화 시점을 2초 뒤로 판단하였고, 프로세서(180)는 매 1초마다 오토 스탑 시스템 제어 모델을 이용하여 엔진 점화 시점을 결정한다고 가정한다. 이 경우, 프로세서는 1초 뒤(t9+1초)에 다시 오토 스탑 시스템 제어 모델을 이용하여 엔진 점화 시점을 결정할 수 있고, 그 결과 0.5초 뒤에 엔진을 점화하는 것으로 결정된 경우에는, 0.5초 뒤(t9+1.5초)에 엔진을 점화할 수 있다.

[432]

[433] 전술한 본 발명은, 프로그램이 기록된 매체에 컴퓨터가 읽을 수 있는 코드로서 구현하는 것이 가능하다. 컴퓨터가 읽을 수 있는 매체는, 컴퓨터 시스템에 의하여 읽혀질 수 있는 데이터가 저장되는 모든 종류의 기록장치를 포함한다. 컴퓨터가 읽을 수 있는 매체의 예로는, HDD(Hard Disk Drive), SSD(Solid State Disk), SDD(Silicon Disk Drive), ROM, RAM, CD-ROM, 자기 테이프, 플로피 디스크, 광 데이터 저장 장치 등이 있다.

[434] 상기와 같이 설명된 인공 지능 장치는 상기 설명된 실시 예들의 구성과 방법이 한정되게 적용될 수 있는 것이 아니라, 상기 실시 예들은 다양한 변형이 이루어질 수 있도록 각 실시 예들의 전부 또는 일부가 선택적으로 조합되어 구성될 수도 있다.

청구범위

[청구항 1] 오토 스탑 기능을 제어하는 인공 지능 장치에 있어서,
차량의 주변에 대한 영상 정보, 상기 차량의 주변에 대한 소리 정보, 상기 차량의 브레이크 정보 또는 상기 차량의 속도 정보 중에서 적어도 하나 이상을 수신하는 입력부;
오토 스탑 기능 제어 모델을 저장하는 저장부; 및
상기 입력부를 통하여 교통 정보 또는 주행 정보 중에서 적어도 하나 이상에 관련된 입력 데이터를 획득하고, 상기 입력 데이터로부터 상기 오토 스탑 기능의 제어의 판단에 이용되는 기반 데이터를 획득하고, 상기 기반 데이터와 상기 오토 스탑 기능 제어 모델을 이용하여 엔진 점화 시점 또는 엔진 점화 여부를 결정하고, 상기 결정된 엔진 점화 시점 또는 상기 결정된 엔진 점화 여부에 따라 자동으로 상기 차량의 엔진을 점화하는 프로세서
를 포함하고,
상기 엔진 점화 시점은
상기 입력 데이터를 획득한 시점 또는 상기 결정 시점으로부터 얼마만큼 이후에 엔진을 점화할 것인지를 의미하고,
상기 엔진 점화 여부는
상기 입력 데이터를 획득한 시점 또는 상기 결정 시점에 엔진을 점화할 것인지 여부를 의미하는, 인공 지능 장치.

[청구항 2] 청구항 1에 있어서,
상기 오토 스탑 기능 제어 모델은
각 차량마다 또는 각 사용자마다 구분하여 개별적으로 설정된 개인화 모델인 것인, 인공 지능 장치.

[청구항 3] 청구항 2에 있어서,
상기 프로세서는
실시간으로 또는 미리 설정된 주기마다 상기 입력 데이터를 획득하고, 상기 차량이 정차하고 상기 오토 스탑 기능에 의하여 상기 엔진이 정지한 경우에만 상기 엔진 점화 여부 또는 상기 엔진 점화 시점을 결정하는, 인공 지능 장치.

[청구항 4] 청구항 3에 있어서,
상기 프로세서는
상기 획득한 입력 데이터를 상기 저장부에 저장하고, 상기 저장된 입력 데이터를 이용하여 각 입력 데이터에 대하여 상기 엔진 점화 시점 또는 상기 엔진 점화 여부에 대한 라벨을 추가하여 갱신용 학습 데이터를 생성하고,
상기 각 입력 데이터의 라벨을 상기 각 입력 데이터의 수집 시점 또는

상기 수집 시점 이후에 최초로 상기 차량을 다시 주행시키기 위한 제어가 수행되는 시점 정보를 고려하여 결정하는, 인공 지능 장치.

[청구항 5] 청구항 2에 있어서,
디스플레이 또는 스피커 중에서 적어도 하나 이상을 포함하는 출력부를 더 포함하고,
상기 프로세서는
상기 출력부를 통하여 상기 결정된 엔진 점화 시점 또는 상기 결정된 엔진 점화 여부에 따른 엔진 점화 정보를 출력하는, 인공 지능 장치.

[청구항 6] 청구항 5에 있어서,
상기 엔진 점화 정보는
상기 프로세서의 제어에 의하여 상기 차량의 엔진이 자동으로 점화되었음을 알리는 정보 또는 상기 차량의 엔진을 자동으로 점화하는 제어에 대한 평가를 요청하는 정보 중에서 적어도 하나 이상을 포함하는, 인공 지능 장치.

[청구항 7] 청구항 2에 있어서,
상기 오토 스탑 기능 제어 모델은
상기 기반 데이터의 각 항목들에 대한 규칙이나 조건들에 대한 충족 여부에 따른 상기 엔진 점화 시점 또는 엔진 점화 여부를 결정하는 규칙 기반 제어 모델인 것인, 인공 지능 장치.

[청구항 8] 청구항 2에 있어서,
상기 오토 스탑 기능 제어 모델은
학습용 교통 정보 및 학습용 주행 정보와 그에 상응하는 라벨링된 엔진 점화 시점 또는 엔진 점화 여부가 포함된 학습 데이터를 이용하여 지도 학습된 인공 신경망 기반 제어 모델이고,
상기 인공 신경망 기반 제어 모델은
상기 학습용 교통 정보 및 상기 학습용 주행 정보에서 입력 특징 벡터가 추출되어 입력되면 상기 엔진 점화 시점 또는 상기 엔진 점화 여부에 대한 결정 결과가 대상 특징 벡터로서 출력되고, 상기 출력된 대상 특징 벡터와 상기 라벨링된 상기 엔진 점화 시점 또는 상기 엔진 점화 여부의 차이에 상응하는 손실 함수를 최소화하도록 학습되는 것인, 인공 지능 장치.

[청구항 9] 청구항 8에 있어서,
상기 인공 신경망 기반 제어 모델은
외부의 인공 신경망의 학습 장치에서 학습된 것이거나, 인공 신경망의 학습을 수행하는 러닝 프로세서를 통하여 학습된 것이고,
상기 프로세서는
상기 인공 신경망 기반 제어 모델이 상기 학습 장치에서 학습된 경우, 사용자의 요청을 수신하거나 설정된 업데이트 시점의 도래 또는 상기 학습 장치로부터 업데이트 알림을 수신하면, 상기 학습 장치에 상기 인공

신경망 기반 제어 모델의 업데이트 정보를 요청하여 수신하고, 상기 수신한 업데이트 정보를 이용하여 상기 인공 신경망 기반 제어 모델을 업데이트하는, 인공 지능 장치.

[청구항 10] 청구항 9에 있어서,
상기 프로세서는
상기 입력부를 통하여 상기 결정된 엔진 점화 시점 또는 상기 결정된 엔진 점화 여부에 대한 사용자의 피드백을 획득하고, 상기 오토 스탑 기능 제어 모델의 갱신에 사용하기 위하여 상기 획득한 피드백과 상기 피드백에 상응하는 상기 입력 데이터를 포함하는 갱신용 학습 데이터를 생성하는, 인공 지능 장치.

[청구항 11] 청구항 10에 있어서,
상기 피드백은
상기 프로세서에 의한 엔진 점화가 적당한 시점인지, 빠른지 또는 느린지에 대한 정보; 상기 엔진 점화가 만족스러운지에 대한 정보; 또는 상기 엔진의 점화를 제어하는 명령 중에서 적어도 하나 이상을 포함하는, 인공 지능 장치.

[청구항 12] 청구항 10에 있어서,
상기 인공 신경망 기반 제어 모델은
상기 갱신용 학습 데이터를 추가적으로 반영하여 학습된 것인, 인공 지능 장치.

[청구항 13] 청구항 2에 있어서,
상기 입력 데이터는
교통량 정보, 신호 정보, 주변 환경 정보 및 차량 주행 상태 정보 중에서 적어도 하나 이상을 포함하는, 인공 지능 장치.

[청구항 14] 프로세서가 차량의 주변에 대한 영상 정보, 상기 차량의 주변에 대한 소리 정보, 상기 차량의 브레이크 정보 또는 상기 차량의 속도 정보 중에서 적어도 하나 이상을 수신하는 입력부를 통하여 교통 정보 또는 주행 정보 중에서 적어도 하나 이상에 관련된 입력 데이터를 획득하는 단계;
상기 프로세서가 상기 입력 데이터로부터 상기 오토 스탑 기능의 제어의 판단에 이용되는 기반 데이터를 획득하는 단계;
상기 프로세서가 상기 기반 데이터와 상기 오토 스탑 기능 제어 모델을 이용하여 엔진 점화 시점 또는 엔진 점화 여부를 결정하는 단계; 및
상기 프로세서가 상기 결정된 엔진 점화 시점 또는 상기 결정된 엔진 점화 여부에 따라 자동으로 상기 차량의 엔진을 점화하는 단계
를 포함하고,
상기 엔진 점화 시점은
상기 입력 데이터를 획득한 시점 또는 상기 결정 시점으로부터 얼마만큼 이후에 엔진을 점화할 것인지를 의미하고,

상기 엔진 점화 여부는
상기 입력 데이터를 획득한 시점 또는 상기 결정 시점에 엔진을 점화할 것인지 여부를 의미하는, 제어 방법.

[청구항 15] 오토 스탑 기능을 제어하는 제어 방법을 수행하기 위한 프로그램이 기록된 기록 매체에 있어서,
상기 제어 방법은
프로세서가 차량의 주변에 대한 영상 정보, 상기 차량의 주변에 대한 소리 정보, 상기 차량의 브레이크 정보 또는 상기 차량의 속도 정보 중에서 적어도 하나 이상을 수신하는 입력부를 통하여 교통 정보 또는 주행 정보 중에서 적어도 하나 이상에 관련된 입력 데이터를 획득하는 단계;
상기 프로세서가 상기 입력 데이터로부터 상기 오토 스탑 기능의 제어의 판단에 이용되는 기반 데이터를 획득하는 단계;
상기 프로세서가 상기 기반 데이터와 상기 오토 스탑 기능 제어 모델을 이용하여 엔진 점화 시점 또는 엔진 점화 여부를 결정하는 단계; 및
상기 프로세서가 상기 결정된 엔진 점화 시점 또는 상기 결정된 엔진 점화 여부에 따라 자동으로 상기 차량의 엔진을 점화하는 단계
를 포함하고,
상기 엔진 점화 시점은
상기 입력 데이터를 획득한 시점 또는 상기 결정 시점으로부터 얼마만큼 이후에 엔진을 점화할 것인지를 의미하고,
상기 엔진 점화 여부는
상기 입력 데이터를 획득한 시점 또는 상기 결정 시점에 엔진을 점화할 것인지 여부를 의미하는, 기록 매체.

[도1]

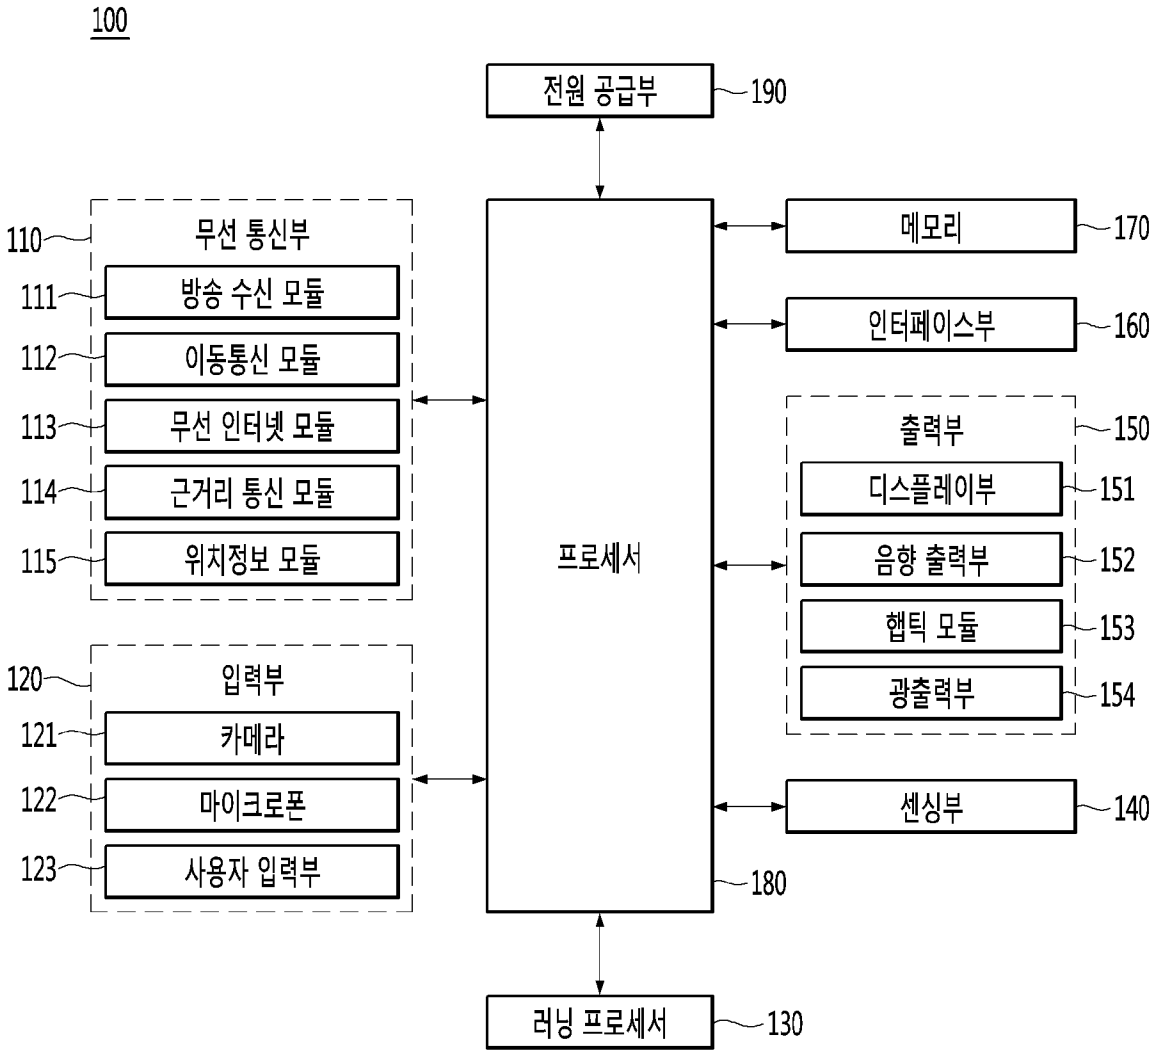
100
전원 공급부
190
무선 통신부
110
방송 수신 모듈
111
이동통신 모듈
112
무선 인터넷 모듈
113
근거리 통신 모듈
114
위치정보 모듈
115
입력부
120
카메라
121
마이크로폰
122
사용자 입력부
123
프로세서
180
메모리
170
인터페이스부
160
출력부
150
디스플레이부
151
음향 출력부
152
햅틱 모듈
153
광출력부
154
센싱부
140
러닝 프로세서
130

[도2]

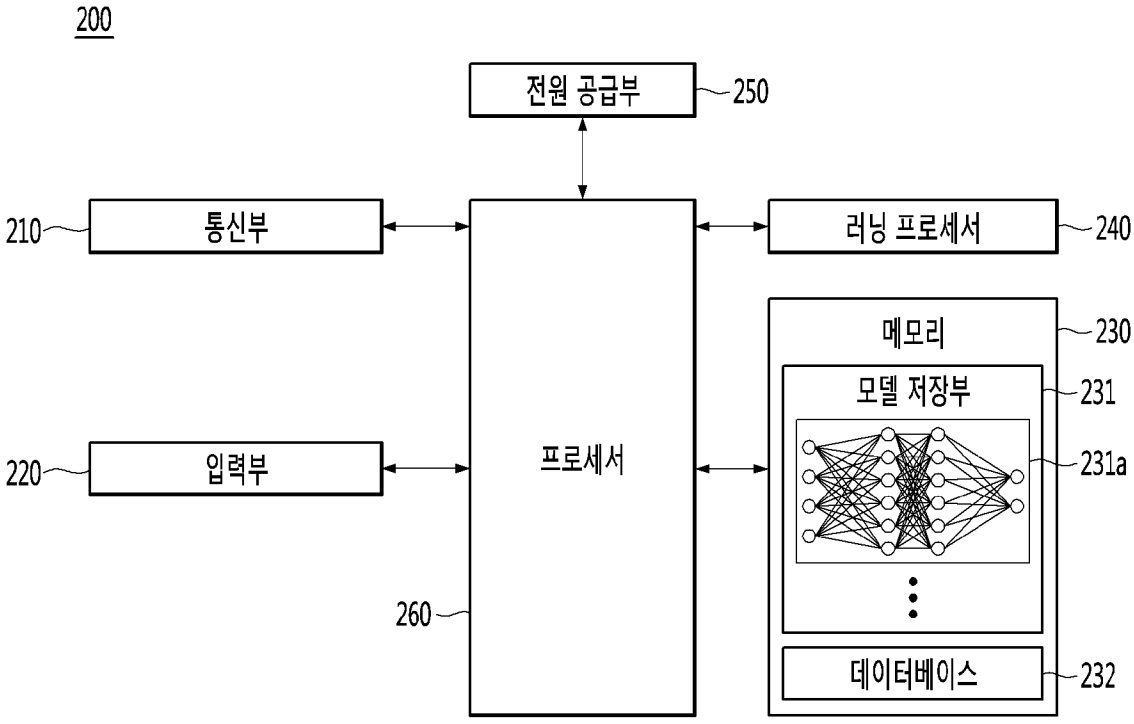
200
전원 공급부
250
통신부
210
입력부
220
프로세서
260
러닝 프로세서
240
메모리
230
모델 저장부
231
231a
데이터베이스
232

[도3]

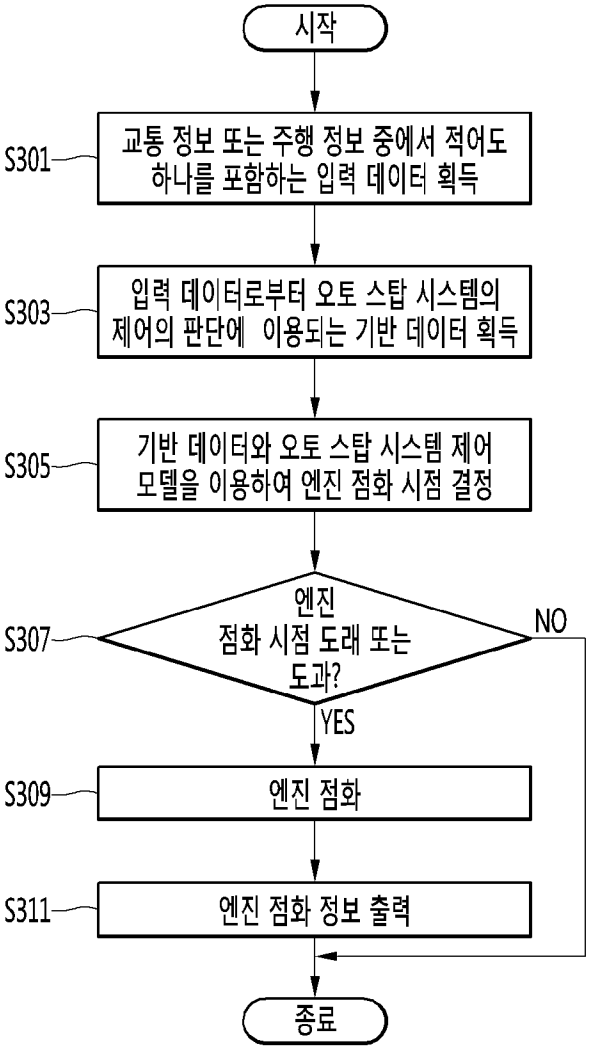
시작
S301
교통 정보 또는 주행 정보 중에서 적어도 하나를 포함하는 입력 데이터 획득
S303
입력 데이터로부터 오토 스탑 시스템의 제어의 판단에 이용되는 기반 데이터 획득
S305
기반 데이터와 오토 스탑 시스템 제어 모델을 이용하여 엔진 점화 시점 결정
S307
엔진 점화 시점 도래 또는 도과?
NO
YES
S309
엔진 점화
S311
엔진 점화 정보 출력
종료

[도4]

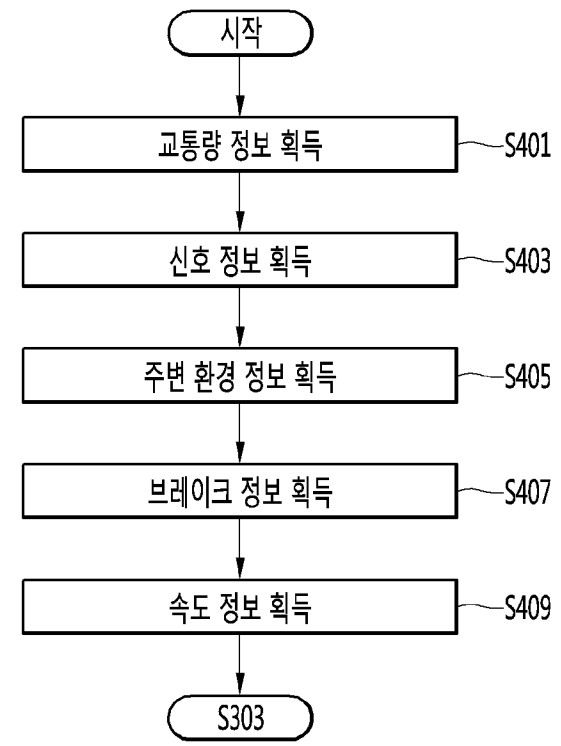
S301
시작
교통량 정보 획득
S401
신호 정보 획득
S403
주변 환경 정보 획득
S405
브레이크 정보 획득
S407
속도 정보 획득
S409
S303

[도5]

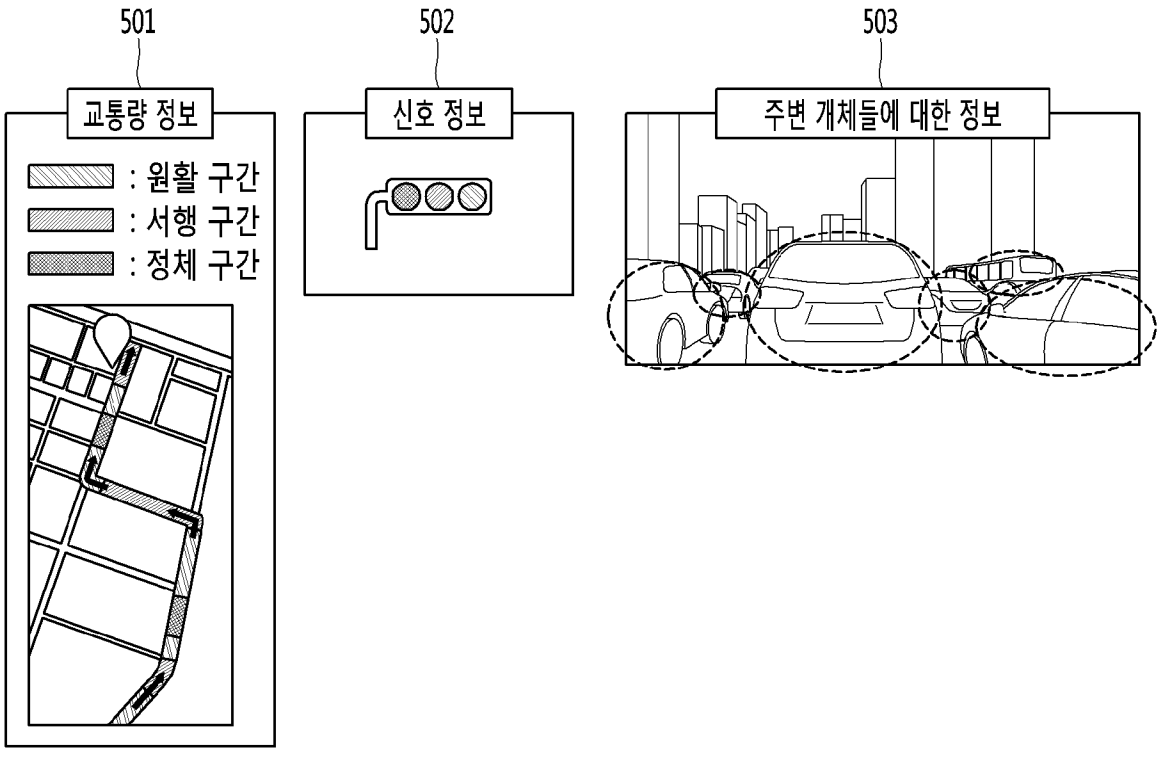
501
교통량 정보
: 원활 구간
: 서행 구간
: 정체 구간
502
신호 정보
503
주변 개체들에 대한 정보

[도6]

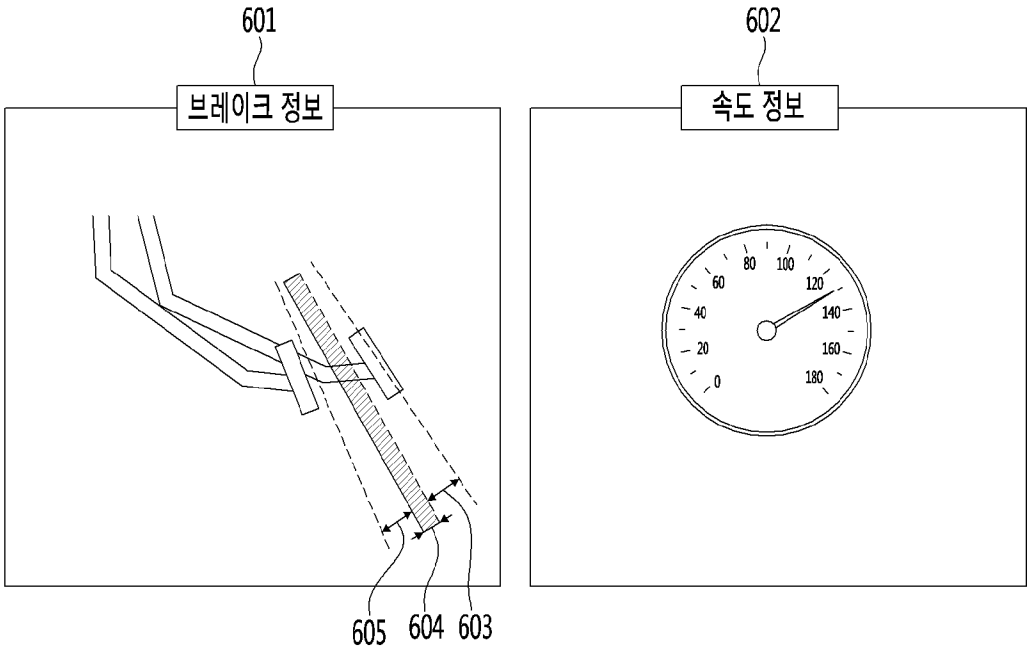

[도7]

구간 정보	신호 정보	앞 차량 브레이크 등	엔진 점화 여부
		On	
		Off	
		On	
		Off	
		On	
		Off	
		On	
		Off	
		On	
		Off	
		On	
		Off	

: 원활 구간
: 서행 구간
: 정체 구간
: 초록 불
: 빨간 불
: 엔진 점화
: 엔진 비점화

[도8]

패턴	현재 교통량 정보	제1 이전 시점 교통량 정보	현재 신호 정보	제1 이전 시점 신호 정보	현재 차량 속도	제1 이전 시점 차량 속도	현재 앞 차량 속도	제1 이전 시점 앞 차량 속도	사용자 피드백
패턴1									엔진 점화
패턴2									엔진 비점화
패턴3									엔진 점화
패턴4									엔진 점화
...									

[도9]

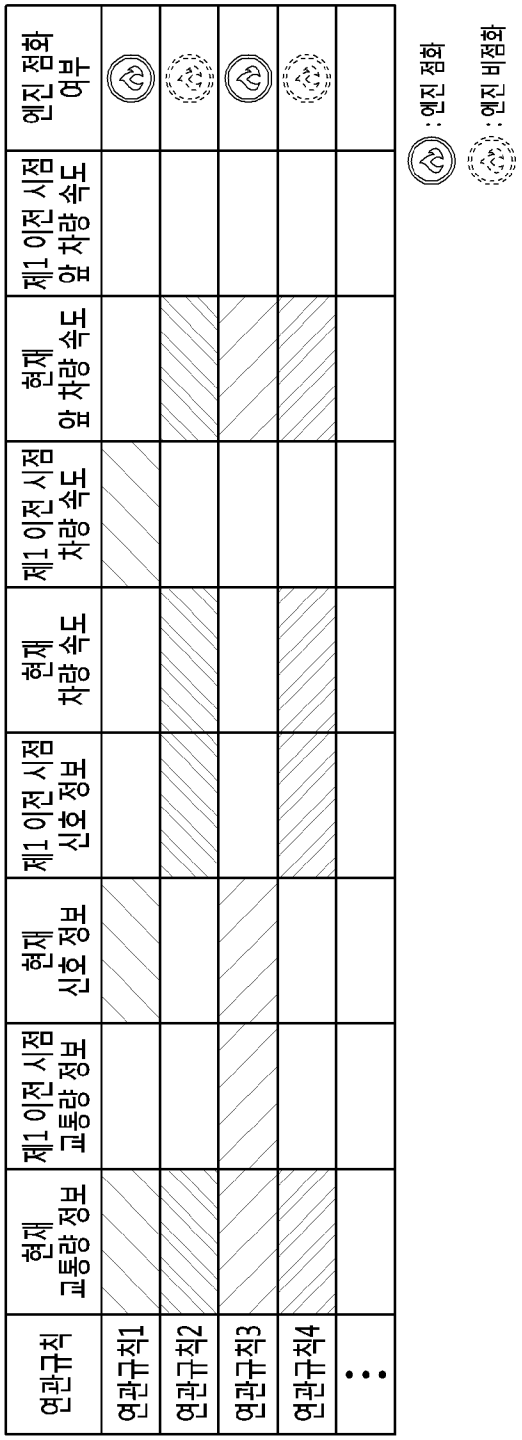
연관규칙
현재 교통량 정보
제1 이전 시점 교통량 정보
현재 신호 정보
제1 이전 시점 신호 정보
현재 차량 속도
제1 이전 시점 차량 속도
현재 앞 차량 속도
제1 이전 시점 앞 차량 속도
엔진 점화 여부
연관규칙1
연관규칙2
연관규칙3
연관규칙4
...
: 엔진 점화
: 엔진 비점화

[도10]

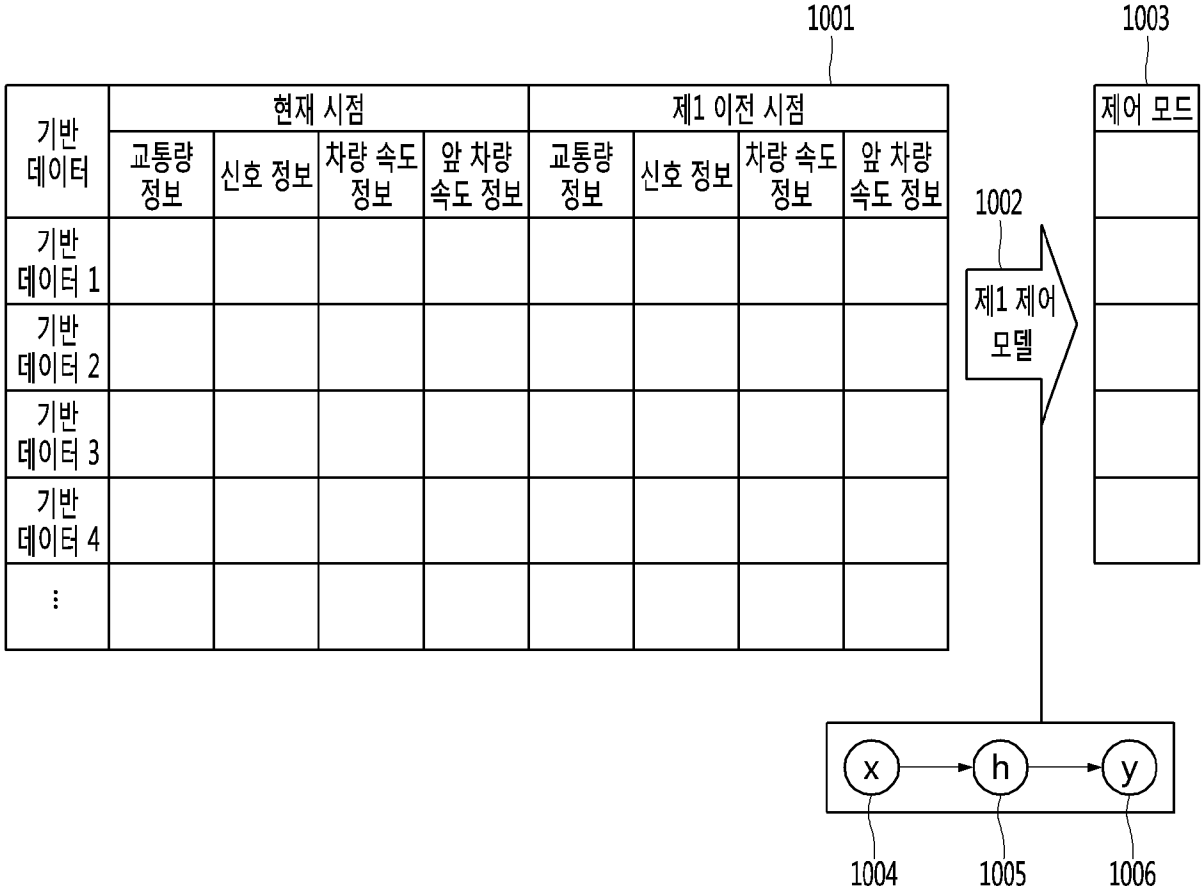
1001
1003
기반 데이터
현재 시점
제1 이전 시점
교통량 정보
신호 정보
차량 속도 정보
앞 차량 속도 정보
교통량 정보
신호 정보
차량 속도 정보
앞 차량 속도 정보
제어 모드
기반 데이터 1
기반 데이터 2
기반 데이터 3
기반 데이터 4
1002
제1 제어 모델
x
h
y
1004
1005
1006

[도11]

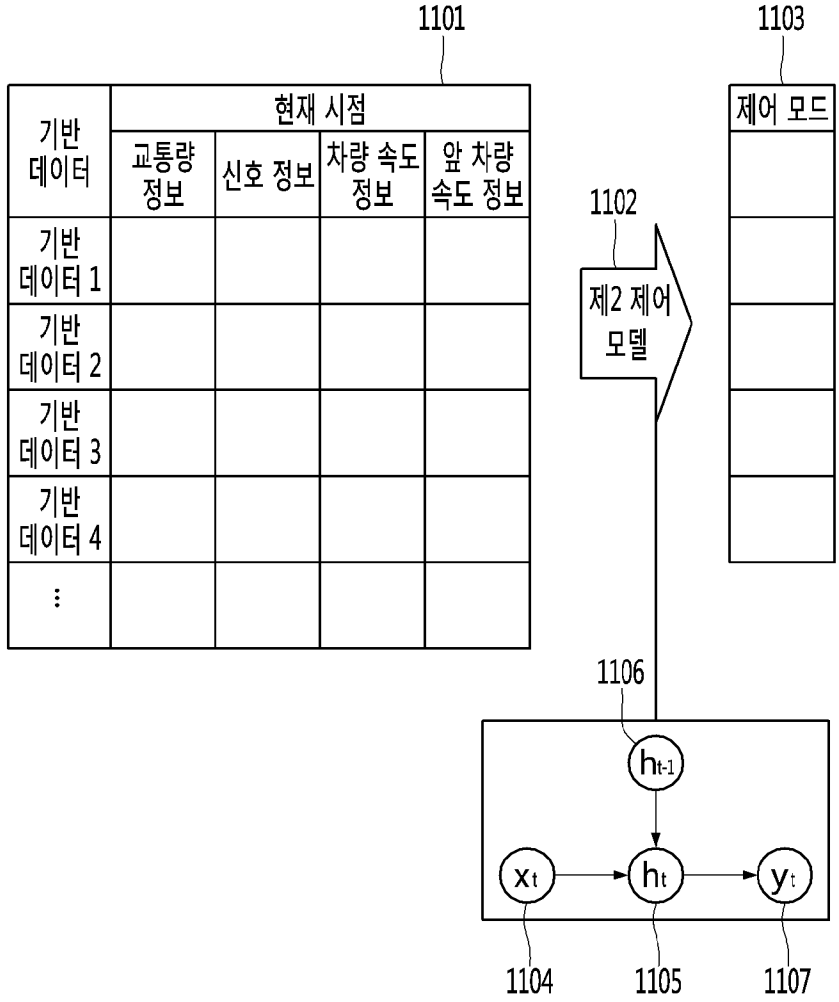
1101
1103
기반 데이터
현재 시점
교통량 정보
신호 정보
차량 속도 정보
앞 차량 속도 정보
기반 데이터 1
기반 데이터 2
기반 데이터 3
기반 데이터 4
제어 모드
1102
제2 제어 모델
1106
ht-1
xt
ht
yt
1104
1105
1107

[도12]

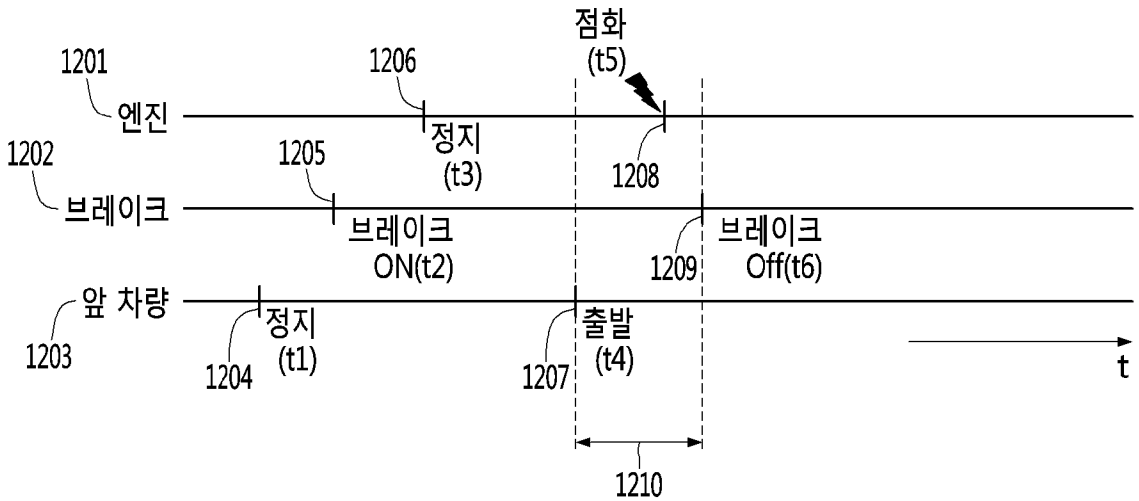
점화 (t5)
1201
엔진
1206
정지 (t3)
1208
1202
브레이크
1205
브레이크 ON(t2)
1209
브레이크 Off(t6)
앞 차량
1203
정지 (t1)
1204
출발 (t4)
1207
t
1210

INTERNATIONAL SEARCH REPORT

International application No.
PCT/KR2019/002792

A. CLASSIFICATION OF SUBJECT MATTER
F02P 5/15(2006.01)i, F02D 41/04(2006.01)i, B60W 10/06(2006.01)i, B60W 30/18(2006.01)i, B60W 30/14(2006.01)i, B60W 40/02(2006.01)i, B60W 50/14(2012.01)i
According to International Patent Classification (IPC) or to both national classification and IPC

B. FIELDS SEARCHED

Minimum documentation searched (classification system followed by classification symbols)
F02P 5/15; B60W 10/06; B60W 20/00; B60W 30/18; F02D 17/00; F02D 29/02; F02D 41/04; F02D 41/06; F02N 11/00; B60W 30/14; B60W 40/02; B60W 50/14

Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched
Korean utility models and applications for utility models: IPC as above
Japanese utility models and applications for utility models: IPC as above

Electronic data base consulted during the international search (name of data base and, where practicable, search terms used)
eKOMPASS (KIPO internal) & Keywords: autostop, idle stop and go, input, memory, processor, traffic information, ignition, neural network

C. DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
Y	KR 10-2017-0060434 A (HYUNDAI MOTOR COMPANY) 01 June 2017 See paragraphs [0040]-[0048] and figure 1.	1-15
Y	KR 10-2017-0033612 A (LG ELECTRONICS INC.) 27 March 2017 See paragraphs [0071], [0101], [0106], [0150]-[0153] and figure 3.	1-15
Y	CN 106428008 A (SOUTH CHINA UNIVERSITY OF TECHNOLOGY) 22 February 2017 See abstract and paragraphs [0005]-[0018].	4,8-12
Y	KR 10-1378037 B1 (ELECTRONICS AND TELECOMMUNICATIONS RESEARCH INSTITUTE) 27 March 2014 See paragraph [0047] and claim 1.	5-6
A	JP 2013-036384 A (SUZUKI MOTOR CORP.) 21 February 2013 See abstract and claims 1-3.	1-15
A	US 2015-0175149 A1 (FORD GLOBAL TECHNOLOGIES, L.L.C.) 25 June 2015 See abstract, claims 1-3, 8-9 and figures 1, 3.	1-15

☐ Further documents are listed in the continuation of Box C. ☒ See patent family annex.

* Special categories of cited documents:
"A" document defining the general state of the art which is not considered to be of particular relevance
"E" earlier application or patent but published on or after the international filing date
"L" document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified)
"O" document referring to an oral disclosure, use, exhibition or other means
"P" document published prior to the international filing date but later than the priority date claimed
"T" later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention
"X" document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone
"Y" document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art
"&" document member of the same patent family

Date of the actual completion of the international search	Date of mailing of the international search report
06 DECEMBER 2019 (06.12.2019)	**06 DECEMBER 2019 (06.12.2019)**
Name and mailing address of the ISA/KR Korean Intellectual Property Office Government Complex Daejeon Building 4, 189, Cheongsa-ro, Seo-gu, Daejeon, 35208, Republic of Korea Facsimile No. +82-42-481-8578	Authorized officer Telephone No.

INTERNATIONAL SEARCH REPORT
Information on patent family members

International application No.
PCT/KR2019/002792

Patent document cited in search report	Publication date	Patent family member	Publication date
KR 10-2017-0060434 A	01/06/2017	None	
KR 10-2017-0033612 A	27/03/2017	None	
CN 106428008 A	22/02/2017	None	
KR 10-1378037 B1	27/03/2014	DE 102010042768 A1	09/06/2011
		JP 2011-099441 A	19/05/2011
		KR 10-2011-0049640 A	12/05/2011
		US 2011-0106413 A1	05/05/2011
JP 2013-036384 A	21/02/2013	None	
US 2015-0175149 A1	25/06/2015	CN 104724112 A	24/06/2015
		DE 102014118272 A1	25/06/2015

국 제 조 사 보 고 서

국제출원번호
PCT/KR2019/002792

A. 발명이 속하는 기술분류(국제특허분류(IPC))

F02P 5/15(2006.01)i, F02D 41/04(2006.01)i, B60W 10/06(2006.01)i, B60W 30/18(2006.01)i, B60W 30/14(2006.01)i, B60W 40/02(2006.01)i, B60W 50/14(2012.01)i

B. 조사된 분야

조사된 최소문헌(국제특허분류를 기재)
F02P 5/15; B60W 10/06; B60W 20/00; B60W 30/18; F02D 17/00; F02D 29/02; F02D 41/04; F02D 41/06; F02N 11/00; B60W 30/14; B60W 40/02; B60W 50/14

조사된 기술분야에 속하는 최소문헌 이외의 문헌
한국등록실용신안공보 및 한국공개실용신안공보: 조사된 최소문헌란에 기재된 IPC
일본등록실용신안공보 및 일본공개실용신안공보: 조사된 최소문헌란에 기재된 IPC

국제조사에 이용된 전산 데이터베이스(데이터베이스의 명칭 및 검색어(해당하는 경우))
eKOMPASS(특허청 내부 검색시스템) & 키워드: 오토스탑, 아이들스탑(idle stop and go), 입력부(input), 저장부(memory), 프로세서(processor), 교통정보(traffic information), 엔진점화(ignition), 인공신경망(neural network)

C. 관련 문헌

카테고리*	인용문헌명 및 관련 구절(해당하는 경우)의 기재	관련 청구항
Y	KR 10-2017-0060434 A (현대자동차 주식회사) 2017.06.01 단락 [0040]-[0048] 및 도면 1 참조.	1-15
Y	KR 10-2017-0033612 A (엘지전자 주식회사) 2017.03.27 단락 [0071], [0101], [0106], [0150]-[0153] 및 도면 3 참조.	1-15
Y	CN 106428008 A (SOUTH CHINA UNIVERSITY OF TECHNOLOGY) 2017.02.22 요약 및 단락 [0005]-[0018] 참조.	4,8-12
Y	KR 10-1378037 B1 (한국전자통신연구원) 2014.03.27 단락 [0047] 및 청구항 1 참조.	5-6
A	JP 2013-036384 A (SUZUKI MOTOR CORP.) 2013.02.21 요약 및 청구항 1-3 참조.	1-15
A	US 2015-0175149 A1 (FORD GLOBAL TECHNOLOGIES, L.L.C.) 2015.06.25 요약, 청구항 1-3, 8-9 및 도면 1, 3 참조.	1-15

☐ 추가 문헌이 C(계속)에 기재되어 있습니다.

☒ 대응특허에 관한 별지를 참조하십시오.

* 인용된 문헌의 특별 카테고리:

"A" 특별히 관련이 없는 것으로 보이는 일반적인 기술수준을 정의한 문헌

"D" 본 국제출원에서 출원인이 인용한 문헌

"E" 국제출원일보다 빠른 출원일 또는 우선일을 가지나 국제출원일 이후에 공개된 선출원 또는 특허 문헌

"L" 우선권 주장에 의문을 제기하는 문헌 또는 다른 인용문헌의 공개일 또는 다른 특별한 이유(이유를 명시)를 밝히기 위하여 인용된 문헌

"O" 구두 개시, 사용, 전시 또는 기타 수단을 언급하고 있는 문헌

"P" 우선일 이후에 공개되었으나 국제출원일 이전에 공개된 문헌

"T" 국제출원일 또는 우선일 후에 공개된 문헌으로, 출원과 상충하지 않으며 발명의 기초가 되는 원리나 이론을 이해하기 위해 인용된 문헌

"X" 특별한 관련이 있는 문헌. 해당 문헌 하나만으로 청구된 발명의 신규성 또는 진보성이 없는 것으로 본다.

"Y" 특별한 관련이 있는 문헌. 해당 문헌이 하나 이상의 다른 문헌과 조합하는 경우로 그 조합이 당업자에게 자명한 경우 청구된 발명은 진보성이 없는 것으로 본다.

"&" 동일한 대응특허문헌에 속하는 문헌

국제조사의 실제 완료일	국제조사보고서 발송일
2019년 12월 06일 (06.12.2019)	2019년 12월 06일 (06.12.2019)

ISA/KR의 명칭 및 우편주소
대한민국 특허청
(35208) 대전광역시 서구 청사로 189,
4동 (둔산동, 정부대전청사)
팩스 번호 +82-42-481-8578

심사관
방승훈
전화번호 +82-42-481-5560

국제조사보고서
대응특허에 관한 정보

국제출원번호
PCT/KR2019/002792

국제조사보고서에서 인용된 특허문헌	공개일	대응특허문헌	공개일
KR 10-2017-0060434 A	2017/06/01	없음	
KR 10-2017-0033612 A	2017/03/27	없음	
CN 106428008 A	2017/02/22	없음	
KR 10-1378037 B1	2014/03/27	DE 102010042768 A1 JP 2011-099441 A KR 10-2011-0049640 A US 2011-0106413 A1	2011/06/09 2011/05/19 2011/05/12 2011/05/05
JP 2013-036384 A	2013/02/21	없음	
US 2015-0175149 A1	2015/06/25	CN 104724112 A DE 102014118272 A1	2015/06/24 2015/06/25