



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2018-0086602
(43) 공개일자 2018년08월01일

(51) 국제특허분류(Int. Cl.)
G08G 1/01 (2006.01) G06N 99/00 (2010.01)
(52) CPC특허분류
G08G 1/0133 (2013.01)
G06N 99/005 (2013.01)
(21) 출원번호 10-2017-0010225
(22) 출원일자 2017년01월23일
심사청구일자 없음

(71) 출원인
충남대학교산학협력단
대전광역시 유성구 대학로 99 (궁동, 충남대학교)
(72) 발명자
김경섭
대전광역시 서구 대덕대로175번길 46, 408호
전우혁
대전광역시 유성구 궁동로2번길 17-2, 307호
(뒷면에 계속)
(74) 대리인
홍성욱, 심경식


전체 청구항 수 : 총 1 항

(54) 발명의 명칭 기계학습을 이용한 교통 정체 구간 추정 장치 및 방법

(57) 요약

기상 데이터, 교통 데이터 및 도로 위치 데이터 중 적어도 하나의 데이터를 수집하는 데이터 수집부, 교통 데이터, 도로 위치 데이터 및 기상 데이터를 병합하여 병합 데이터를 생성하는 병합 데이터 생성부 및 병합 데이터를 기계학습에 기초하여 학습하여 날씨별 교통 정체 구간을 예측하는 결정트리 모델(Decision Tree Model)을 생성하는 기계학습부를 포함하는, 기계학습을 이용한 교통 정체 구간 추정 장치 및 그 방법에 관한 것이다.

대표도 - 도1



(72) 발명자

박경빈

경상북도 구미시 형곡동로 103, 1506호

최지인

대구광역시 수성구 달구벌대로492길 17

이 발명을 지원한 국가연구개발사업

과제고유번호 1711035534

부처명 미래창조과학부

연구관리전문기관 정보통신기술진흥센터

연구사업명 정보통신기술인력양성

연구과제명 2016년 SW중심대학(ICT/SW창의연구과정)_충남대

기 여 율 1/1

주관기관 충남대학교 산학협력단

연구기간 2016.03.01 ~ 2017.02.28

명세서

청구범위

청구항 1

기상 데이터, 교통 데이터 및 도로 위치 데이터 중 적어도 하나의 데이터를 수집하는 데이터 수집부;

상기 교통 데이터, 상기 도로 위치 데이터 및 상기 기상 데이터를 병합하여 병합 데이터를 생성하는 병합 데이터 생성부; 및

상기 병합 데이터를 기계학습에 기초하여 학습하여 날씨별 교통 정체 구간을 예측하는 결정 트리 모델(Decision Tree Model)을 생성하는 기계학습부를 포함하는, 기계학습을 이용한 교통 정체 구간 추정 장치.

발명의 설명

기술 분야

[0001] 본 발명은 기계학습을 이용하여 교통 정체 구간을 추정하기 위한 기계학습을 이용한 교통 정체 구간 추정 장치 및 방법에 관한 것이다.

배경 기술

[0002] 최근 정보통신기술의 발달로 등장한 "빅데이터"는 기존의 소프트웨어로는 저장, 관리, 분석이 어려운 데이터라고 정의할 수 있으며, "빅데이터"의 활용을 통해 사회 현안 및 사용자의 니즈 파악, 미래전략 수립, 선제적 공공서비스 제공 등 각종 서비스가 제공될 수 있다.

[0003] 이러한 "빅데이터" 중 기상기후 빅데이터는 기상 기후에 관련된 각종 정보를 포함하는 "빅데이터"로 이러한 기상기후 빅데이터는 기상자료의 분석, 미래 기상 정보 예측, 에너지 관광, 날씨보험과 같은 타 산업과의 융합을 통해 신 사업 창출이 가능한 날씨에 관한 빅데이터를 의미할 수 있다.

[0004] 이러한, 기상기후 빅데이터는 개인의 신상을 바탕으로 한 정보가 아니기 때문에 개인 정보 보호의 문제에서 자유로울 수 있으며, 이러한 기상기후 빅데이터와 사회경제적 자료를 접목하면 시너지 효과를 발휘할 수 있다.

[0005] 교통 정체는 사고나 공사, 날씨 등 많은 요인들의 영향을 받게 되며, 더 나아가 사고는 운전자의 부주의로 인한 것일지라도 날씨의 영향을 종종 받는 경우도 있으나, 종래에는 날씨가 교통에 얼마나 영향을 미치는지에 대해 효과적으로 알 수가 없는 문제가 있다.

선행기술문헌

특허문헌

[0006] (특허문헌 0001) 한국 등록특허공보 제10-0695918호(2007.03.09.)

발명의 내용

해결하려는 과제

[0007] 본 발명의 목적은, 상기 문제점을 해결하기 위한 것으로 기상 데이터 및 교통 데이터를 연계하여 기계학습함으로써 날씨별 교통 정체 구간을 예측하는 결정 트리 모델을 생성하여, 교통 정체 구간을 추정하기 위한 것이다.

[0008] 본 발명이 해결하고자 하는 과제는 이상에서 언급한 과제(들)로 제한되지 않으며, 언급되지 않은 또 다른 과제(들)은 아래의 기재로부터 당업자에게 명확하게 이해될 수 있을 것이다.

과제의 해결 수단

[0009] 상기한 목적을 달성하기 위하여, 본 발명의 실시예에 따른 기계학습을 이용한 교통 정체 구간 추정 장치는 기상

데이터, 교통 데이터 및 도로 위치 데이터 중 적어도 하나의 데이터를 수집하는 데이터 수집부, 교통 데이터, 도로 위치 데이터 및 기상 데이터를 병합하여 병합 데이터를 생성하는 병합 데이터 생성부 및 병합 데이터를 기계학습에 기초하여 학습하여 날씨별 교통 정체 구간을 예측하는 결정 트리 모델(Decision Tree Model)을 생성하는 기계학습부를 포함한다.

발명의 효과

[0010] 본 발명의 일 실시예에 따르면, 교통 정체 구간을 추정하기 위하여 기상 데이터 및 교통 데이터를 동시에 활용하기 때문에, 보다 정확한 날씨별 교통 정체 구간을 추정할 수 있다.

도면의 간단한 설명

[0011] 도 1은 본 발명의 실시예에 따른, 교통 정체 구간 추정 장치를 설명하기 위한 구성도이다.

도 2는 본 발명의 실시예에 따른, 교통 정체 구간 추정 장치가 활용하는 기상 데이터를 설명하기 위한 도면이다.

도 3은 본 발명의 실시예에 따른, 교통 정체 구간 추정 장치가 활용하는 교통 데이터를 설명하기 위한 도면이다.

도 4는 본 발명의 실시예에 따른, 교통 정체 구간 추정 장치가 활용하는 도로 위치 데이터를 설명하기 위한 도면이다.

도 5는 본 발명의 실시예에 따른, 교통 정체 구간 추정 장치에 포함되는 병합 데이터 생성부를 설명하기 위한 도면이다.

도 6 내지 도 8은 본 발명의 실시예에 따른, 교통 정체 구간 추정 장치에 포함되는 기계학습부를 설명하기 위한 도면이다.

발명을 실시하기 위한 구체적인 내용

[0012] 이하, 본 발명이 속하는 기술분야에서 통상의 지식을 가진 자가 본 발명의 기술적 사상을 용이하게 실시할 수 있을 정도로 상세히 설명하기 위하여, 본 발명의 가장 바람직한 실시예를 첨부 도면을 참조하여 설명하기로 한다. 우선 각 도면의 구성요소들에 참조부호를 부가함에 있어서, 동일한 구성요소들에 대해서는 비록 다른 도면상에 표시되더라도 가능한 한 동일한 부호를 가지도록 하고 있음에 유의해야 한다. 또한, 본 발명을 설명함에 있어, 관련된 공지 구성 또는 기능에 대한 구체적인 설명이 본 발명의 요지를 흐릴 수 있다고 판단되는 경우에는 그 상세한 설명은 생략한다.

[0013] 이하, 본 발명의 실시예에 따른 기계학습을 이용한 교통 정체 구간 추정 장치 및 방법을 첨부된 도면을 참조하여 상세하게 설명하면 아래와 같다.

[0014] 도 1에 도시된 바와 같이, 본 발명의 실시예에 따른 기계학습을 이용한 교통 정체 구간 추정 장치(100)는 데이터 수집부(110), 병합 데이터 생성부(120) 및 기계학습부(130)를 포함한다.

[0015] 데이터 수집부(110)는 기상 데이터, 교통 데이터 및 도로 위치 데이터 중 적어도 하나의 데이터를 수집한다.

[0016] 병합 데이터 생성부(120)는 교통 데이터, 도로 위치 데이터 및 기상 데이터를 병합하여 병합 데이터를 생성한다.

[0017] 기계학습부(130)는 병합 데이터를 기계학습에 기초하여 학습하여 날씨별 교통 정체 구간을 예측하는 결정 트리 모델(Decision Tree Model)을 생성한다.

[0018] 예를 들어, 본 발명의 실시예에 따른 기계학습을 이용한 교통 정체 구간 추정 장치(100)는 기상 데이터와 교통 데이터를 수집한 후, 분산 시스템 환경 하에서 실행되는 기계학습 알고리즘을 이용하여 기상기후와 관련된 교통 정체 구간을 추정하는 장치를 의미할 수 있다.

[0019] 다시 말해, 본 발명의 실시예에 따른 기계학습을 이용한 교통 정체 구간 추정 장치(100)는 대량의 날씨 데이터, 교통 데이터를 분석하여, 날씨에 따른 주요 도로의 교통 흐름이 어떻게 될 것인지 예측할 수 있다.

[0020] 본 발명의 실시예에 따른 기계학습을 이용한 교통 정체 구간 추정 장치(100)는 대량의 날씨 데이터와 교통 데이

터를 분석하고 예측하기 위해서 통계 분석 툴과 분산 처리 시스템을 활용할 수 있다.

- [0021] 일 실시예에 따르면, 기계학습을 이용한 교통 정체 구간 추정 장치(100)는 통계 소프트웨어 개발과 자료 분석에 널리 사용되고 있는 처리 시스템의 대표적인 솔루션 하둡(Hadoop)을 사용할 수 있으며, 하둡 위에 스파크(Spark), 맵 리듀스(MapReduce), 하둡 분산 파일 시스템(Hadoop Distributed File System, HDFS), 하둡 플랫폼을 위한 공개 비관계형 분산 데이터 베이스인 H베이스(HBASE), 하둡 2.0인 얀(Yet, Another Resource Negotiator, YARN)를 설치하여 대량의 데이터를 효과적으로 분석할 수 있다.
- [0022] 예컨대, 기계학습을 이용한 교통 정체 구간 추정 장치(100)는 분산 처리 시스템 상에서 대용량의 데이터를 안정적으로 저장하기 위해 하둡 분산 파일 시스템을 사용하고, H베이스를 통해 분산 시스템 상태를 관리할 수 있으며, 맵리듀스, 얀을 이용해 분산 데이터를 처리하고, 스파크의 기계학습을 이용해서 데이터를 분석할 수 있다.
- [0023] 예컨대, 아파치 하둡(Apache Hadoop, High-Availability Distributed Object-Oriented Platform)은 대량의 자료를 처리할 수 있는 큰 컴퓨터 클러스터에서 동작하는 분산 응용 프로그램을 지원하는 프리웨어 자바 소프트웨어 프레임워크이며, 너치의 분산 처리를 지원하기 위해 개발된 것으로, 아파치 루씬의 하부 프로젝트를 의미할 수 있으며, 아파치 하둡은 분산처리 시스템인 구글 파일 시스템을 대체할 수 있는 하둡 분산 파일 시스템(HDFS: Hadoop Distributed File System)과 맵 리듀스(Map Reduce)를 구현한다.
- [0024] 하둡 분산 파일 시스템(HDFS, Hadoop distributed file system)은 하둡 프레임워크를 위해 자바 언어로 작성된 분산 확장 파일 시스템으로, 하둡 분산 파일 시스템은 여러 기계에 대용량 파일들을 나눠서 저장하고, 데이터들을 여러 서버에 중복해서 저장을 함으로써 데이터 안정성을 얻는다.
- [0025] 하둡 분산 파일 시스템을 채용하는 경우 호스트에 레이드(RAID) 저장장치를 사용하지 않아도 되며, 하둡 분산 파일 시스템은 마스터/슬레이브(master/slave) 구조를 가지되, 하둡 분산 파일 시스템의 클러스터는 하나의 네임노드와, 파일 시스템을 관리하고 클라이언트의 접근을 통제하는 마스터 서버로 구성되며, 클러스터의 각 노드에는 데이터 노드가 하나씩 존재하고, 이 데이터 노드는 실행될 때마다 노드에 추가되는 스토리지를 관리한다.
- [0026] 맵리듀스(Map Reduce)는 구글에서 대용량 데이터 처리를 분산 병렬 컴퓨팅에서 처리하기 위한 목적으로 제작하여 2004년 발표한 소프트웨어 프레임워크로, 맵리듀스는 페타바이트 이상의 대용량 데이터를 신뢰도가 낮은 컴퓨터로 구성된 클러스터 환경에서 병렬 처리를 지원하기 위해서 개발되었으며, 맵리듀스는 함수형 프로그래밍에서 일반적으로 사용되는 맵(Map)과 리듀스(Reduce)라는 함수 기반으로 주로 구성된다.
- [0027] 아파치 스파크는 범용적 목적의 분산 고성능 클러스터링 플랫폼(General purpose high performance distributed platform)으로, 캘리포니아 버클리 대학의 AMPLab에서 개발 된 오픈 소스 클러스터 컴퓨팅 프레임워크로 후에 아파치 소프트웨어 재단에 기증되어 현재 아파치 재단에서 관리되고 있다.
- [0028] 하둡이 맵리듀스(MapReduce) 작업을 디스크 기반으로 수행해서 느려지는 것과 대조적으로 스파크는 메모리 기반으로 옮겨서 빠른 성능을 제공하며, 스파크의 주요기능으로 맵리듀스(MapReduce), 스트리밍(Streaming) 데이터 핸들링, SQL 기반의 데이터 쿼리, 머신러닝 라이브러리, 그래프 데이터 프로세싱 등이 있다.
- [0029] 이제 도 2 내지 도 4를 참조하여, 데이터 수집부(110)가 수집하는 기상 데이터, 교통 데이터 및 도로 위치 데이터의 실시예를 설명한다.
- [0030] 도 2는 본 발명의 실시예에 따른, 교통 정체 구간 추정 장치가 활용하는 기상 데이터를 설명하기 위한 도면이다. 도 3은 본 발명의 실시예에 따른, 교통 정체 구간 추정 장치가 활용하는 교통 데이터를 설명하기 위한 도면이다. 도 4는 본 발명의 실시예에 따른, 교통 정체 구간 추정 장치가 활용하는 도로 위치 데이터를 설명하기 위한 도면이다.
- [0031] 예컨대, 데이터 수집부(110)가 수집하는 기상 데이터는 도 2에 도시된 바와 같을 수 있으며, 지점, 일시, 평균기온, 최저기온, 최고기온 시각, 최고기온, 일 강수량 등의 기상데이터를 CSV 파일의 형태로 수집한 데이터를 의미할 수 있다.
- [0032] 예컨대, 데이터 수집부(110)가 수집하는 교통 데이터는 도 3에 도시된 바와 같을 수 있으며, 소통정보 데이터를 CSV 파일 형태로 수집한 데이터를 의미할 수 있다.
- [0033] 예컨대, 데이터 수집부(110)가 수집하는 도로 위치 데이터는 도 4에 도시된 바와 같을 수 있으며, 표준노드링크에서 도로 위치를 CSV 파일 형태로 수집한 데이터를 의미할 수 있다.
- [0034] 이때, 데이터 수집부(110)가 수집한 각각의 데이터 형태는 CSV 파일 형태인 것으로 설명되었으나, 본 발명은 이

에 한정되지 않는다.

[0035] 이제 도 5를 참조하여, 병합 데이터 생성부(120)를 설명한다.

[0036] 도 5는 본 발명의 실시예에 따른, 교통 정체 구간 추정 장치에 포함되는 병합 데이터 생성부를 설명하기 위한 도면이다.

[0037] 병합 데이터 생성부(120)는 기계학습부(130)가 결정 트리 모델(Decision Tree Model)을 생성하기 위하여, 데이터 구축을 위한 각종 데이터들과 그 데이터들을 효율적으로 정리, 축소하기 위해서 기상 데이터, 교통 데이터 및 도로 위치 데이터를 병합하여 병합 데이터를 생성함으로써 전처리한다.

[0038] 예컨대, 병합 데이터 생성부(120)는 각 지역별로 데이터를 전처리를 하기 위해서 날씨 데이터를 여러 대도시(고속도로) 별로 나누고, 정체구간의 시간과 날씨 데이터에서의 시간을 하루치로 통합한다.

[0039] 예를 들어, 날씨 데이터는 하루당 강수량, 일조량, 온도 등 데이터가 포맷 되어 있지만 교통 데이터는 5분당 교통 정보를 담고 있으므로 병합 데이터 생성부(120)는 이들 데이터를 병합하기 위하여 전처리할 수 있다.

[0040] 예컨대, 병합 데이터 생성부(120)의 전처리 방식은 도 5에 도시된 바와 같으며 병합 데이터 생성부(120)는 교통 데이터와 각 지역별 Road ID 값 리스트를 포함하는 도로 위치 데이터를 먼저 통합하고 통합한 데이터와 날씨 데이터를 다시 날짜별로 통합하여 병합 데이터를 생성할 수 있다.

[0041] 이제 도 6 내지 도 8을 참조하여 기계학습부(130)를 설명한다.

[0042] 도 6 내지 도 8은 본 발명의 실시예에 따른, 교통 정체 구간 추정 장치에 포함되는 기계학습부를 설명하기 위한 도면이다.

[0043] 기계학습부(130)는 날씨 데이터와 교통 데이터를 통합한 병합 데이터를 이용하여 의사 결정 트리(Decision Tree) 모델을 통한 날씨에 따른 소통속도와 교통사고를 예측하는 모델을 생성할 수 있으며, 기계학습부(130)는 이러한 예측 기법을 사용하기 위해서 프로그램 R에서 제공하는 C5.0 라이브러리에 포함된 함수인 Decision Tree를 사용할 수 있으며, C5.0 라이브러리는 트리 생성 알고리즘에서 정보획득량을 사용할 수 있으나, 본 발명은 이에 한정되지 않는다.

[0044] 결정 트리 학습법(decision tree learning)은 어떤 항목에 대한 관측값과 목표값을 연결시켜주는 예측 모델로써 결정 트리를 사용하며, 이러한 결정 트리는 시각적이고 명시적인 방법으로 의사 결정 과정과 결정된 의사를 보여주는데 사용될 수 있다.

[0045] 예컨대, 결정 트리 학습법은 데이터 마이닝에서 사용되는 방법으로, 몇몇 입력 변수를 바탕으로 목표 변수의 값을 예측하는 모델을 생성하는 것을 목표로 하며, 결정 트리 학습법은 트리 구조에서, 각 내부 노드들은 하나의 입력 변수에, 자녀 노드들로 이어지는 가지들은 입력 변수의 가능한 값에 대응되고, 잎 노드는 각 입력 변수들이 루트 노드로부터 잎 노드로 이어지는 경로에 해당되는 값들을 가질 때의 목표 변수 값에 해당된다.

[0046] 정보획득량과 관련하여, 주어진 데이터 집합의 혼잡도를 엔트로피로 정의할 때, 가장 혼잡도가 높은 상태는 1, 하나의 클래스로만 구성된 상태는 0으로 나타낼 수 있으며, 정보획득량은 두 확률분포의 차이를 계산하는 데에 사용하는 함수로, 어떤 이상적인 분포에 대해, 그 분포를 근사하는 다른 분포를 사용해 샘플링을 한다면 발생할 수 있는 정보 엔트로피 차이를 계산하는 함수를 의미할 수 있으며, 엔트로피를 산출하는 방법은 아래 수학적 식 1과 같고 정보획득량을 산출하는 방법은 아래 수학적 식 2와 같다.

[0047] [수학적 식 1]

$$\text{Entropy}(S) = - \sum_{i=1}^m p_i \log_2(p_i) \quad \text{여기서 } p_i = \frac{\text{freq}(C_i, S)}{|S|}$$

[0048]

[0049] [수학적 식 2]

$$\text{Gain}(A) = I(s_1, s_2, \dots, s_m) - E(\text{속성 } A)$$

[0050]

- [0051] 예컨대, 기계학습부(130)가 기계학습을 하기 위해서는 분석 시스템에서 분석되어서 나온 데이터를 사용하는데 이때 기계학습을 위한 데이터인 트레이닝 데이터(Training Data)와 트레이닝 된 의사 결정 트리(Decision Tree)에 결과를 확인하기 위한 데이터인 테스트 데이터(Testing Data)가 필요하다.
- [0052] 예컨대, 기계학습부(130)는 기존의 의사 결정 트리(Decision Tree) 모델의 불안정성을 줄이고 정확도를 늘리기 위해서 부트 스트래핑(Bootstrapping) 기법을 사용할 수 있다.
- [0053] 부트 스트래핑 기법은 가설 검증을 하거나 메트릭을 계산하기 전의 랜덤 샘플링(Random Sampling)을 적용하는 방법을 의미할 수 있으며, 중복을 허용해 주어야 하는 것을 특징으로 한다.
- [0054] 부트 스트래핑 기법을 활용하는 경우, 기계학습부(130)는 랜덤 샘플링(Random Sampling)을 통하여 데이터를 추출하는 동작을 기설정된 횟수만큼 반복하여 평균을 취한 데이터를 사용할 수 있으며, 예를 들어 기온과 오존층의 관계를 부트 스트래핑한 결과는 도 6에 도시된 바와 같을 수 있으며, 도 6에서 회색선은 랜덤 샘플링된 데이터이고 빨간선이 부트 스트래핑이 적용된 데이터를 의미할 수 있으나, 본 발명은 이에 한정되지 않는다.
- [0055] 예컨대, 기계학습부(130)는 날씨 데이터의 온도, 눈, 비와 교통 데이터의 차량속도의 연관관계를 의사 결정 트리(Decision Tree) 모델링으로 예측할 수 있으며, 의사 결정 트리(Decision Tree) 모델의 차량속도(0~100km/h)는 빠름(Fast), 보통(Normal), 느림(Slow)으로 구성할 수 있다.
- [0056] 예컨대, 기계학습부(130)는 predict() 함수를 사용하여 테스트 데이터(Testing Data)를 넣어 나오는 결과 테이블을 사용할 수 있으며, 예측 모델의 정확도와 테이블은 도 7에 도시된 바와 같고, 의사 결정 트리 모델은 도 8에 도시된 바와 같으며, 정확도는 32.2%로 낮은 에러율을 보임을 확인할 수 있다.
- [0057] 즉, 본 발명의 실시예에 따른, 기계학습을 이용한 교통 정체 구간 추정 장치(100)는 의사 결정 트리 모델링 예측 결과를 통해서 수집한 날씨 데이터와 교통 데이터의 상관관계를 추정할 수 있다.
- [0058] 즉, 본 발명의 실시예에 따른, 기계학습을 이용한 교통 정체 구간 추정 장치(100)를 통해 사용자는 해당 도로의 날씨에 따른 예측 소통 정보를 활용할 수 있으며, 사용자는 도로 교통 정보를 예상하고 제공하는 새로운 방법의 일환으로 사용자들이 예상되는 도로 교통 정보를 통해 최적의 길을 안내할 수 있는 효과가 있다.
- [0059] 이상에서 본 발명에 따른 바람직한 실시예에 대해 설명하였으나, 다양한 형태로 변형이 가능하며, 본 기술분야에서 통상의 지식을 가진 자라면 본 발명의 특허청구범위를 벗어남이 없이 다양한 변형예 및 수정예를 실시할 수 있을 것으로 이해된다.


부호의 설명

- [0060] 100: 기계학습을 이용한 교통 정체 구간 추정 장치
 110: 데이터 수집부
 120: 병합 데이터 생성부
 130: 기계학습부

도면

도면1

100



도면2

지점	일시	평균기온(°)	최저기온(°)	최저기온(°)	최고기온(°)	최고기온(°)	강수	계속, 10분	최다 10분	최다 1시간	최다 1시간	최다 일강수량()
90	2015-01-01	-4.6	-7.9	757	-1.8	1156						
90	2015-01-02	-2.9	-5.4	2258	0.9	1430						
90	2015-01-03	1.1	-7.2	153	6.9	1331						
90	2015-01-04	5.8	1.9	2342	10.4	1335						
90	2015-01-05	7.3	2.2	212	12.2	1716						
90	2015-01-06	3.4	-2.4	2336	8.6	41	1.67					0
90	2015-01-07	-2.2	-6.7	640	3.1	1444						
90	2015-01-08	-0.5	-4.9	28	5.3	1327						
90	2015-01-09	1.5	-2.7	645	6.3	1331						
90	2015-01-10	3.1	-0.5	437	6.4	1501						
90	2015-01-11	1.8	-1.3	2159	4.6	356	2.5					0
90	2015-01-12	-0.2	-4.7	641	4.9	1423						
90	2015-01-13	3.2	-3	137	8.3	1456						
90	2015-01-14	4.8	-0.4	117	8	1157						
90	2015-01-15	3.4	1.1	2136	4.8	253	11.5					0.5
90	2015-01-16	2.9	0	258	7.2	1142						
90	2015-01-17	0.8	-3.4	646	5.3	1440						
90	2015-01-18	2.8	-0.3	521	6.1	1416						
90	2015-01-19	3.4	0.1	2113	7	1351	0.5					0
90	2015-01-20	1.3	-2.8	439	5.9	1326						


도면3

2015-01-01 0:00	1000000301	7	0	0	77	0	0	0
2015-01-01 0:00	1000000302	7	0	0	62	0	0	0
2015-01-01 0:00	1000000303	7	0	0	27	0	0	0
2015-01-01 0:00	1000000401	21	0	0	26	0	0	0
2015-01-01 0:00	1000000402	21	0	0	21	0	0	0
2015-01-01 0:00	1000000403	21	0	0	9	0	0	0
2015-01-01 0:00	1000000501	10	0	0	24	0	0	0
2015-01-01 0:00	1000000502	11	0	0	60	0	0	0
2015-01-01 0:00	1000000503	10	0	0	61	0	0	0
2015-01-01 0:00	1000000601	11	0	0	22	0	0	0
2015-01-01 0:00	1000000602	11	0	0	60	0	0	0
2015-01-01 0:00	1000000603	8	0	0	77	0	0	0
2015-01-01 0:00	1000000701	35	0	0	5	0	0	0
2015-01-01 0:00	1000000702	35	0	0	17	0	0	0
2015-01-01 0:00	1000000703	35	0	0	5	0	0	0
2015-01-01 0:00	1000000801	38	0	0	4	0	0	0
2015-01-01 0:00	1000000802	38	0	0	16	0	0	0


도면4

RoadId	start	startname	end	endname	grade	Roadname	Roadlen	pos
1000003501	1120008500	서대문아트	1010027000	서대문아트	104	의주로	66	서울특별시
1000003502	1120009400	롯데리아	1120008500	서대문아트	104	의주로	121	서울특별시
1000003503	1120010000	금화초교앞	1120009400	롯데리아	104	의주로	193	서울특별시
1000003504	1120011300	교남동사동	1120010000	금화초교앞	104	의주로	336	서울특별시
1000003505	1120011800	독립문_의	1120011300	교남동사동	104	의주로	123	서울특별시
1000003506	1120012200	독립문	1120011800	독립문_의	104	의주로	64	서울특별시
1000003601	1010027000	서대문아트	1120008600	서대문아트	104	의주로	64	서울특별시
1000003602	1120008600	서대문아트	1120009400	롯데리아	104	의주로	121	서울특별시
1000003603	1120009400	롯데리아	1120010000	금화초교앞	104	의주로	193	서울특별시
1000003604	1120010000	금화초교앞	1120011300	교남동사동	104	의주로	338	서울특별시
1000003605	1120011300	교남동사동	1120011900	독립문_의	104	의주로	124	서울특별시
1000003606	1120011900	독립문_의	1120012200	독립문	104	의주로	58	서울특별시
1000005101	1000007300	세종로사거리	1000002000	동아일보로	104	태평로	76	서울특별시
1000005102	1000009000	세종로사거리	1000007300	세종로사거리	104	태평로	40	서울특별시
1000005201	1000002000	동아일보로	1000007400	세종로사거리	104	태평로	77	서울특별시
1000005202	1000007400	세종로사거리	1000009000	세종로사거리	104	태평로	39	서울특별시
1000005700	1010035200	다산교(북문)	1010035100	오간수교(남문)	104	청계천로	543	서울특별시
1000005800	1010034700	오간수교(남문)	1010005300	신평화시장	104	청계천로	215	서울특별시
1000005900	1000011200	충로5가	1010035000	청계5가	104	훈원로	139	서울특별시
1000006000	1010035000	청계5가	1000011200	충로5가	104	훈원로	139	서울특별시

도면5



도면6



도면7

Evaluation on training data (143 cases):

```

Decision Tree
-----
Size      Errors
      7  46(32.2%)  <<

```

```

(a)  (b)  (c)  <-classified as
-----
 31    2    3  (a): class fast
 15   13   19  (b): class normal
  6    1   53  (c): class slow

```

Attribute usage:

```

100.00% temper_value
 45.45% snow_value
 42.66% rain_value

```

Time: 0.0 secs

```

> p1<-predict(m1,test)
> table(test[,1],p1)
      p1
      fast normal slow
fast    11      3    5
normal  10      3   12
slow     4      1   27

```

도면8

