데이터 과학 심층 분석: SQL Server 에서 RevoScaleR 패키지 사용하기

원문:https://docs.microsoft.com/ko-kr/sql/advanced-analytics/tutorials/deepdive-data-science-deep-dive-using-the-revoscaler-packages

검토 및 편집: 김정선(jskim@sqlroad.com), Microsoft Data Platform MVP

이 자습서에는 고성능 빅 데이터 분석을 위한 계산 컨텍스트로 서버를 사용함으로써 R Services(In-Database)에서 제공하는 향상된 R 패키지를 사용하여 SQL Server 데이터를 작업하고 확장 가능한 R 솔루션을 만드는 방법을 보여줍니다.

로컬 및 원격 계산 컨텍스트 간에 데이터를 이동 하는 원격 계산 컨텍스트를 만들고 원격 SQL Server 에서 R 코드를 실행하는 방법을 학습합니다. 또한 로컬 및 원격 서버에서 데이터를 분석 하고 표시하는 방법과 모델을 만들고 배포하는 방법을 학습합니다.

참고

이 자습서에서는 Windows 의 SQL Server 데이터를 사용하여 작업하고 데이터베이스 내 계산 컨텍스트를 사용합니다. Teradata, Linux, Hadoop 과 같은 다른 환경에서 R 를 사용하려면 다음 Microsoft R Server 자습서를 참조합니다.

- R 서버 sparklyr 와 함께 사용
- Explore R and ScaleR in 25 Functions(25 개 함수에서 R 및 ScaleR 알아보기)
- Hadoop MapReduce 에 ScaleR 시작

개요

RevoScaleR 패키지의 유연성과 처리 능력을 경험하기위해 이 자습서에서 데이터의 이동과 계산 컨텍스트 전환을 자주 합니다. 설명을 위해 이 자습서의 일부 작업은 다음과 같습니다:

- 데이터는 초기에 CSV 파일 또는 XDF 파일에서 가져온 것입니다. RevoScaleR 패키지에서 함수를 사용해서 SQL Server 로 데이터를 가져옵니다.
- SQL Server 계산 컨텍스트를 사용해서 모델 학습 및 채점을 수행합니다.
- RevoScaleR 함수를 사용해서 채점 결과를 저장하는 SQL Server 테이블을 만듭니다.
- 서버와 로컬 계산 컨텍스트에서 플롯을 만듭니다.
- SQL Server 인스턴스에서 R 를 실행하는, SQL Server 데이터베이스 내 데이터에 대한 모델을 학습시킵니다.
- 데이터의 하위 세트를 추출하고 로컬 워크스테이션에서 분석 작업에 재사용하도록 XDF 파일에 저장합니다.
- SQL Server 데이터베이스에 ODBC 연결을 열어 채점을 위하 새 데이터를 가져옵니다. 채점은 로컬 워크스테이션에서 수행합니다.
- 사용자 지정 R 함수를 만들고 서버 계산 컨텍스트에서 실행하여 시뮬레이션을 수행합니다.

필요한 시간 및 항목 목록

이 자습서는 설치를 제외하고 약 75 분 정도 소요됩니다.

1. R 을 사용하여 SQL Server 데이터 작업하기
2. RxSqlServerData 를 사용하여 SQL Server 데이터 개체 만들기
3. SQL Server 데이터 쿼리 및 수정하기
4. 계산 컨텍스트 정의 및 사용하기
5. R 스크립트 만들기 및 실행하기
6. R 을 사용하여 SQL Server 데이터 시각화하기

7. R 모델 만들기
8. 새 데이터 채점하기
9. R 을 사용하여 데이터 변환하기
10. rxImport 를 사용하여 메모리에 데이터 로드하기
11. rxDataStep 를 사용하여 새 SQL Server 테이블 만들기
12. rxDataStep 을 사용하여 청크 단위로 분석하기
13. 로컬 계산 컨텍스트에서 데이터 분석하기
14. XDF 파일을 사용하여 SQL Server 에서 데이터 이동하기
15. 간단한 시뮬레이션 만들기

대상 사용자

이 자습서는 모델 작성과 요약과 같은 데이터 과학 작업을 하는 데이터 과학자 또는 R 에 이미 어느 정도 친숙한 사람들을 대상으로 합니다. 그러나 모든 코드가 제공되므로 R 을 처음 사용하는 경우에도 필요한 서버 및 클라이언트 환경이 있다면 코드를 실행하고 따라할 수 있습니다.

또한 Transact-SQL 구문에 익숙하며 다음과 같은 도구를 사용해서 SQL Server 데이터베이스를 액세스하는 방법을 알고 있어야 합니다:

- SQL Server Management Studio
- Visual Studio 에서 데이터베이스 도구
- 무료 Visual Studio Code 용 mssql extension

팁

중단한 위치부터 다시 시작하기 쉽도록 다음 단원으로 넘어가기 전에 R 작업 영역을 저장하세요.

사전 요구 사항

- **R 을 지원하는 SQL Server**

  SQL Server 2016 을 설치하고 R Services (In-database)를 사용하도록 설정합니다. 또는 SQL Server 2017 을 설치하고 Machine Learning Services 를 사용하도록 설정하고 R 언어를 선택합니다.

- 데이터베이스 사용 권한

  모델 학습에 사용되는 쿼리를 실행하려면 데이터가 저장된 데이터베이스에 대한 **db_datareader** 권한이 있어야 합니다. R 을 실행하려면 사용자에게 EXECUTE ANY EXTERNAL SCRIPT 권한이 있어야 합니다.

- 데이터 과학 개발 컴퓨터

  R 개발 환경으로 사용되는 컴퓨터에는 RevoScaleR 패키지 및 관련된 공급자를 설치해야 합니다. 가장 쉬운 방법은 Microsoft R Client, Microsoft R Server (독립 실행형) 또는 Machine Learning Server (독립 실행형)를 설치하는 것입니다.

  참고

  다른 버전의 Revolution R Enterprise 또는 Revolution R Open 은 지원되지 않습니다.

  RevoScaleR 함수만 원격 계산 컨텍스트를 사용할 수 있으므로 이 자습서에서는 R 의 오픈 소스 배포를 사용할 수 없습니다.

- 추가 **R** 패키지

  이 자습서에서는 다음 패키지를 설치합니다: **dplyr**, **ggplot2**, **ggthemes**, **reshape2**, 및 **e1071**. 설명서는 자습서의 일부로 제공됩니다.

두 위치에 모든 패키지를 설치해야 함: R 솔루션을 개발하는 컴퓨터와 R 스크립트를 실행하는 SQL Server 컴퓨터. 서버 컴퓨터에 패키지를 설치할 수 있는 권한이 없는 경우 관리자에게 요청합니다.

사용자 라이브러리에 패키지를 설치하지 마세요. 패키지는 SQL Server 인스턴스에서 사용되는 R 패키지 라이브러리에 설치되어야 합니다.

자세한 내용은 데이터 과학 연습에 대한 필수 구성 요소를 참조합니다.

다음 단계

R 을 사용하여 SQL Server 데이터 작업

R를 사용하여 SQL Server 데이터 작업(SQL과 R 심층 분석)

이 단원에서는 환경을 설정하고 모델 학습에 필요한 데이터를 추가하고 데이터에 대한 간략한 요약을 실행합니다. 절차의 일부로 다음 작업을 완료해야 합니다.

- 두 개의 R 모델을 학습하고 채점하기 위한 데이터를 저장할 새 데이터베이스를 만듭니다.
- 워크스테이션과 SQL Server 컴퓨터 간에 통신할 때 사용할 계정(Windows 사용자 또는 SQL 로그인)을 만듭니다.
- SQL Server 데이터와 데이터베이스 개체로 작업하기 위한 데이터 원본을 R 에서 만듭니다.
- R 데이터 원본을 사용하여 데이터를 SQL Server 에 로드합니다.
- R 을 사용하여 변수 목록을 가져오고 SQL Server 테이블의 메타데이터를 수정합니다.
- R 코드의 원격 실행이 가능하도록 계산 컨텍스트를 만듭니다.
- (선택 사항) 원격 계산 컨텍스트에서 추적을 사용합니다.

데이터베이스와 사용자 만들기

이 연습에서 SQL Server 2017 에 새 데이터베이스를 만들고, 데이터를 읽고 쓸 수 있으며 R 스크립트를 실행할 수 있는 사용 권한을 가진 SQL 로그인을 추가합니다.

참고

데이터 읽기만 한다면 R 스크립트를 실행하는 계정에는 지정된 데이터베이스에서 SELECT 사용 권한(**db_datareader** 역할)이 필요합니다. 그러나 이 자습서에서는 데이터베이스를 준비하고 채점 결과를 저장하기 위한 테이블을 만들려면 DDL 관리 권한이 있어야 합니다.

또한 데이터베이스 소유자가 아닌 경우 R 스크립트를 실행하려면 EXECUTE ANY EXTERNAL SCRIPT 사용 권한이 필요 합니다.

1. SQL Server Management Studio 에서 R Services(In-Database) 을 사용할 수 있는 인스턴스를 선택하고 **데이터베이스**를 마우스 오른쪽 단추로 클릭한 다음 **새 데이터베이스**를 선택합니다.
2. 새 데이터베이스의 이름을 입력합니다. 원하는 이름을 임의로 사용할 수 있지만 이 연습의 모든 Transact-SQL 스크립트 및 R 스크립트를 적절하게 편집해야 합니다.

   팁

   업데이트된 데이터베이스 이름을 보려면 **데이터베이스**를 마우스 오른쪽 단추로 클릭하고 **새로 고침**을 선택합니다.

3. **새 쿼리**를 클릭하고 데이터베이스 컨텍스트를 master 데이터베이스로 변경합니다.
4. 새 **쿼리** 창에서 다음 명령을 실행하여 사용자 계정을 만들고 이 자습서에 사용되는 데이터베이스에 할당합니다. 필요한 경우 데이터베이스 이름을 변경해야 합니다.

Windows 사용자

SQL 복사

```
 -- Create server user based on Windows account
USE master
```

```
GO

CREATE LOGIN [<DOMAIN>\<user_name>] FROM WINDOWS WITH
DEFAULT_DATABASE=[DeepDive]



 --Add the new user to tutorial database

USE [DeepDive]

GO

CREATE USER [<user_name>] FOR LOGIN [<DOMAIN>\<user_name>] WITH
DEFAULT_SCHEMA=[db_datareader]
```

SQL 로그인

SQL 복사

```
-- Create new SQL login

USE master

GO

CREATE LOGIN DDUser01 WITH PASSWORD='<type password here>',
CHECK_EXPIRATION=OFF, CHECK_POLICY=OFF;



-- Add the new SQL login to tutorial database

USE [DeepDive]

GO

CREATE USER [DDUser01] FOR LOGIN [DDUser01] WITH
DEFAULT_SCHEMA=[db_datareader]
```

1. 사용자가 만들어졌는지 확인하려면 새 데이터베이스를 선택하고 **보안** 및 **사용자**를 차례로 확장합니다.

문제 해결

이번 섹션에서는 데이터베이스를 설정하는 과정에서 발생할 수 있는 몇 가지 일반적인 문제를 보여 줍니다.

- **데이터베이스 연결을 확인하고 SQL 쿼리를 검사하려면 어떻게 하나요?**

  서버를 사용하여 R 코드를 실행하기 전에 R 개발 환경에서 데이터베이스에 연결할 수 있는지 확인하는 것이 좋습니다. Visual Studio 의 서버 탐색기 및 SQL Server Management Studio 는 둘 다 강력한 데이터베이스 연결 및 관리 기능을 갖춘 무료 도구입니다.

  추가 데이터베이스 관리 도구를 설치하지 않으려는 경우 제어판의 ODBC 데이터 원본 관리자를 사용하여 SQL Server 인스턴스에 대한 테스트 연결을 만들 수 있습니다. 데이터베이스가 올바르게 구성되고 올바른 사용자 이름 및 암호를 입력한 경우 방금 만든 데이터베이스가 표시되며 기본 데이터베이스로 선택할 수 있습니다.

  데이터베이스에 연결할 수 없는 경우 서버에 대해 원격 연결을 사용할 수 있고 명명된 파이프 프로토콜이 사용하도록 설정되었는지 확인합니다. 이 문서에서 추가 문제 해결 팁을 제공: SQL Server 데이터베이스 엔진에 연결 문제를 해결합니다.

- **내 테이블 이름 앞에 datareader 가 붙는 것은 무엇 때문인가요?**

  이 사용자에 대한 기본 스키마로 **db_datareader** 를 지정하는 경우, 이 사용자가 만든 모든 테이블 및 기타 새 개체들의 *스키마* 이름에 사용됩니다. 스키마는 개체를 구성하기 위해 데이터베이스에 추가할 수 있는 폴더와 비슷합니다. 또한 스키마는 데이터베이스 내에서 사용자 권한을 정의합니다.

스키마가 특정 사용자 이름과 연관되어 있으면 사용자는 *스키마 소유자*입니다. 개체를 만들 때, 개체를 다른 스키마에서 작성하도록 특별히 요구하지 않는 한, 항상 자신의 스키마에서 만듭니다.

예를 들어 이름 TestData 로 테이블을 만들 경우, 기본 스키마가 `**db\_datareader**` 라면, 해당 테이블은 <database_name>.db_datareader. TestData 이름으로 만들어집니다.

이러한 이유로 테이블이 서로 다른 스키마에 속하기만 하면 한 데이터베이스에 같은 이름의 테이블이 여러 개 포함될 수 있습니다.

테이블을 찾을 때 스키마를 지정하지 않으면 데이터베이스 서버는 사용자가 소유한 스키마를 찾습니다. 따라서 로그인과 연관된 스키마의 테이블에 액세스할 때는 스키마 이름을 지정하지 않아도 됩니다.

- **DDL 권한이 없습니다. 그래도 자습서를 실행할 수 있나요?**

  예, 그러나 누군가에게 데이터를 SQL Server 테이블에 미리 로드하도록 요청하고 새 테이블을 만드는 섹션을 건너뛰어야 합니다. DDL 권한이 필요한 함수는 자습에서 호출됩니다.

  또한 EXECUTE ANY EXTERNAL SCRIPT 권한을 달라고 관리자에게 요청합니다. 원격 혹은 `sp_execute_external_script` 을 사용해서 R 스크립트를 실행하는데 필요합니다.

다음 단계

RxSqlServerData 를 사용하여 SQL Server 데이터 개체 만들기

개요

데이터 과학 심층 분석: RevoScaleR 패키지 사용

RxSqlServerData를 사용하여 SQL Server 데이터 개체 만들기(SQL과 R 심층 분석)

지금까지 SQL Server 데이터베이스를 만들고 데이터 작업에 필요한 필요한 권한을 얻었습니다. 이 단계에서는 R 에서 데이터 작업을 할 수 있도록 일부 개체를 만듭니다.

SQL Server 데이터 개체 만들기

이 단계에서는 **RevoScaleR** 패키지의 함수를 사용해서 두 개의 테이블을 만들고 데이터를 채웁니다. 한 테이블은 모델 학습에 사용하고 다른 테이블은 채점에 사용합니다. 두 테이블 모두 시뮬레이션된 신용 카드 사기 데이터를 포함합니다.

원격 SQL Server 컴퓨터에서 테이블을 만들기 위해 **RxSqlServerData** 함수를 호출합니다.

팁

R Tools for Visual Studio 를 사용하는 경우, 도구 모음에서 **R Tools** 를 선택하고 **Windows** 를 클릭하여 R 변수 디버깅 및 보기에 대한 옵션을 표시하세요.

학습 데이터 테이블 만들기

1. R 변수에 데이터베이스 연결 문자열을 저장합니다. 다음은 SQL Server 에 대한 유효한 ODBC 연결 문자열의 두 가지 예제: SQL 로그인을 사용하는 것 하나와 Windows 통합 인증 한 개입니다.

   SQL 로그인

   R 복사

   ```
   sqlConnString <- "Driver=SQL Server;Server=instance_name;
   Database=DeepDive;Uid=user_name;Pwd=password"
   ```

   Windows 인증

   R 복사

   ```
   sqlConnString <- "Driver=SQL
   Server;Server=instance_name;Database=DeepDive;Trusted_Connection=Tru
   e"
   ```

   인스턴스 이름, 데이터베이스 이름, 사용자 이름 및 암호를 적절하게 수정해야 합니다.

2. 만들려는 테이블의 이름을 지정하고 R 변수에 저장합니다.

   R 복사

   ```
   sqlFraudTable <- "ccFraudSmall"
   ```

   인스턴스 및 데이터베이스 이름이 연결 문자열의 일부로 이미 지정되었음으로 두 변수를 결합할 경우 새 테이블의 *정규화된* 이름은 *instance.database.schema.ccFraudSmall* 이 됩니다.

3. 데이터 원본 개체를 인스턴스화하기 전에 추가 매개 변수 *rowsPerRead* 를 지정하는 줄을 추가합니다. *rowsPerRead* 매개 변수는 각 배치에서 읽는 데이터 행 수를 제어합니다.

R 복사

```
sqlRowsPerRead = 5000
```

이 매개 변수는 선택 사항이지만 메모리 사용 및 효율적인 계산을 처리하는 데 중요합니다. R Services(In-Database)의 향상된 분석 기능은 대부분 데이터를 청크로 처리하고 중간 결과를 저장하며 모든 데이터를 읽은 후에 최종 계산을 반환합니다.

이 매개 변수의 값이 너무 크면 그만큼 큰 데이터 청크를 효율적으로 처리할 수 있는 메모리가 없어서 데이터 액세스 속도가 느려질 수 있습니다. 일부 시스템에서는 *rowsPerRead* 값이 너무 작아서 성능이 느려질 수 있습니다. 따라서 대량 데이터 세트로 작업하는 경우엔 시스템에서 이 설정값을 시험하는 것이 좋습니다.

이 연습에는 SQL Server 인스턴스에서 정의한 기본 일괄 처리 크기를 사용 하여 각 청크의 행 수를 제어합니다. 해당 값을 `sqlRowsPerRead` 변수에 저장 합니다.

4. 마지막으로, 새 데이터 원본 개체에 대한 변수를 정의하고 이전에 정의한 인수를 RxSqlServerData 생성자에 전달합니다. 이렇게 하면 데이터 원본 개체가 만들어지기만 하고 채워지지는 않습니다.

R 복사

```
sqlFraudDS <- RxSqlServerData(connectionString = sqlConnString,
   table = sqlFraudTable,
   rowsPerRead = sqlRowsPerRead)
```

채점 데이터 테이블을 만들려면

동일한 단계와 절차를 사용해서 채점 데이터를 보관하는 테이블을 만듭니다.

1. 새 R 변수 *sqlScoreTable* 을 만들어 채점에 사용되는 테이블의 이름을 저장합니다.

R 복사

```
sqlScoreTable <- "ccFraudScoreSmall"
```

2. 이 변수를 RxSqlServerData 함수의 인수로 제공해서 두 번째 데이터 원본 개체인 *sqlScoreDS* 를 정의합니다.

R 복사

```
sqlScoreDS \<- RxSqlServerData(connectionString = sqlConnString,
   table = sqlScoreTable, rowsPerRead = sqlRowsPerRead)
```

R 작업 영역에서 이미 연결 문자열과 기타 매개 변수를 변수로 정의했음으로 다른 테이블, 뷰 또는 쿼리에 대한 새 데이터 원본을 쉽게 만들 수 있습니다.

참고

이 함수는 쿼리를 기반으로 데이터 원본 용과 전체 테이블을 기반으로 데이터 원본을 정의하는데 있어서 서로 다른 인수를 사용합니다. 이는 SQL Server 데이터베이스 엔진이 쿼리를 다르게 준비해야하기 때문입니다. 이 자습서의 뒷부분에서 SQL 쿼리를 기반으로 데이터 원본 개체를 만드는 방법을 배웁니다.

R 을 사용하여 SQL 테이블에 데이터를 로드하기

이제 SQL Server 테이블을 만들었으므로 적절한 **Rx** 함수를 사용하여 해당 테이블에 데이터를 로드할 수 있습니다.

RevoScaleR 패키지에는 다양한 데이터 원본을 지원하는 함수가 있습니다. 텍스트 데이터의 경우 RxTextData 를 사용해서 데이터 원본 개체를 생성합니다. Hadoop 데이터, ODBC 데이터 등에서 데이터 원본 개체를 만들기 위한 추가 함수들이 있습니다.

참고

이 섹션을 수행하려면 데이터베이스에 **DDL 실행** 사용 권한이 있어야 합니다.

학습 테이블에 데이터 로드하기

1. R 변수 *ccFraudCsv* 를 만들고 샘플 데이터를 포함하는 CSV 파일의 경로를 변수에 할당합니다.

R 복사

```
ccFraudCsv <- file.path(rxGetOption("sampleDataDir"),
"ccFraudSmall.csv")
```

RevoScaleR 의 rxOptions 에 연관된 GET 메소드인 **rxGetOption** 에 대한 호출을 확인하십시오. 이 유틸리티를 사용하여 기본 공유 디렉터리 또는 계산에 사용할 프로세서(코어) 수와 같은 로컬 및 원격 계산 컨텍스트에 관련된 옵션을 설정하고 나열합니다.

이 특정 호출은 코드를 실행하는 위치에 관계없이 올바른 라이브러리에서 샘플을 가져옵니다. 예를 들어 SQL Server 및 개발 컴퓨터에서 이 함수를 실행해 보고 경로가 어떻게 다른지 확인하세요.

2. 새 데이터를 저장할 변수를 정의하고 **RxTextData** 함수를 사용하여 텍스트 데이터 원본을 지정합니다.

R 복사

```
inTextData <- RxTextData(file = ccFraudCsv,      colClasses = c(
    "custID" = "integer", "gender" = "integer", "state" = "integer",
    "cardholder" = "integer", "balance" = "integer",
    "numTrans" = "integer",
    "numIntlTrans" = "integer", "creditLine" = "integer",
    "fraudRisk" = "integer"))
```

colClasses 인수가 중요합니다. 이 인수를 사용하여 텍스트 파일에서 로드된 데이터의 각 열에 할당할 데이터 형식을 나타냅니다. 이 예제에서는 정수로 처리되는 명명된 열을 제외하고 모든 열이 텍스트로 처리됩니다.

3. 이 시점에서 잠시 멈추고 SQL Server Management Studio 에서 데이터베이스를 볼 수 있습니다. 데이터베이스의 테이블 목록을 새로 고칩니다.

   R 데이터 개체가 로컬 작업 공간에 생성되었지만 SQL Server 데이터베이스에 테이블이 생성되지 않았음을 알 수 있습니다. 또한 텍스트 파일에서 R 변수에 데이터가 로드 되지 않았습니다.

4. 이제 rxDataStep 함수를 호출하여 SQL Server 테이블에 데이터를 삽입합니다.

R 복사

```
rxDataStep(inData = inTextData, outFile = sqlFraudDS, overwrite =
TRUE)
```

연결 문자열에 문제가 없다고 가정하면 잠시 후 다음과 같은 결과가 표시됩니다.

Total Rows written: 10000, Total time: 0.466

Rows Read: 10000, Total Rows Processed: 10000, Total Chunk Time: 0.577 seconds

5. SQL Server Management Studio 를 사용하여 테이블 목록을 새로 고칩니다. 각 변수가 올바른 데이터 형식을 갖고 성공적으로 가져왔는지 확인하려면 SQL Server Management Studio 에서 테이블을 마우스 오른쪽 단추로 클릭하고 **상위 1000 개 행 선택**을 선택합니다.

채점 테이블에 데이터 로드하기

1. 채점용으로 사용되는 데이터 세트를 데이터베이스에 로드하기 위해 단계를 반복합니다.

   먼저 원본 파일의 경로를 제공합니다.

   R 복사

```
ccScoreCsv <- file.path(rxGetOption("sampleDataDir"),
"ccFraudScoreSmall.csv")
```

2. **RxTextData** 함수를 사용하여 데이터를 가져와 *inTextData* 변수에 저장합니다.

   R 복사

```
inTextData <- RxTextData(file = ccScoreCsv,      colClasses = c(
    "custID" = "integer", "gender" = "integer", "state" = "integer",
    "cardholder" = "integer", "balance" = "integer",
    "numTrans" = "integer",
    "numIntlTrans" = "integer", "creditLine" = "integer"))
```

3. **rxDataStep** 함수를 호출하여 현재 테이블을 새 스키마와 데이터로 덮어씁니다.

R 복사

```
rxDataStep(inData = inTextData, sqlScoreDS, overwrite = TRUE)
```

- *inData* 인수는 사용할 데이터 원본을 정의합니다.
- *outFile* 인수는 데이터를 저장할 SQL Server 의 테이블을 지정합니다.
- 테이블이 이미 존재하고 *overwrite* 옵션을 사용하지 않는 경우 결과는 잘림없이 입력됩니다.

연결에 성공하면 완료를 나타내는 메시지와 테이블에 데이터를 기록하는 데 필요한 시간이 표시됩니다.

Total Rows written: 10000, Total time: 0.384

Rows Read: 10000, Total Rows Processed: 10000, Total Chunk Time: 0.456 seconds

RxDataStep 에 대한 추가 정보

rxDataStep 은 R 데이터 프레임에서 여러 변환을 수행할 수 있는 강력한 함수입니다. 또한 rxDataStep 을 사용하여 대상에서 필요로 하는 표현으로 데이터를 변환할 수 있습니다: 이 경우 SQL Server.

선택적으로 **rxDataStep** 에 대한 인수에서 R 함수를 사용하여 데이터에 대해 변환을 지정할 수 있습니다. 이러한 작업의 예는 이 자습서의 뒷부분에서 제공됩니다.

다음 단계

SQL Server 데이터 쿼리 및 수정

이전 단계

R 을 사용하여 SQL Server 데이터 작업

SQL Server 데이터 쿼리 및 수정(SQL 과 R 심층 분석)

이제 데이터를 SQL Server 에 로드했음으로 앞서 만든 데이터 원본을 R Services(In-Database)의 R 함수에 대한 인수로 사용하여 변수에 대한 기본 정보를 가져오고 요약 및 히스토그램을 생성합니다.

이 단계에서는 몇 가지 빠른 분석을 수행한 다음 데이터를 강화 하도록 데이터 원본을 다시 사용 합니다.

데이터 쿼리

먼저, 열과 해당 데이터 형식 목록을 가져옵니다.

1. rxGetVarInfo 함수를 사용하여 분석하려는 데이터 원본을 지정합니다.

   RevoScaleR 의 버전을 따라 rxGetVarNames 를 사용할 수도 있습니다.

   R 복사

```
rxGetVarInfo(data = sqlFraudDS)
```

결과

Var 1: custID, Type: integer

Var 2: gender, Type: integer

Var 3: state, Type: integer

Var 4: cardholder, Type: integer

Var 5: balance, Type: integer

Var 6: numTrans, Type: integer

Var 7: numIntlTrans, Type: integer

Var 8: creditLine, Type: integer

Var 9: fraudRisk, Type: integer

메타 데이터 수정

모든 변수가 정수로 저장되었지만 일부 변수는 범주형 데이터를 나타내며 R 에서는 *요인(factor) 변수*라고 합니다. 예를 들어 *state* 열에는 50 개 주와 콜롬비아 특별구에 대한 식별자로 사용되는 숫자가 포함되어 있습니다. 데이터를 더 쉽게 이해하기위해 숫자를 주 약어 목록으로 바꿉니다.

이 단계에서는 약어를 포함하는 문자열 벡터를 만들고 원래 정수 식별자에 이러한 범주 값을 매핑합니다. 그 다음 *colInfo* 인수에 새 변수를 사용하여 이 열을 요인으로 처리하도록 지정합니다. 데이터를 분석하거나 이동시킬 때마다 약어가 사용되며 열은 요인으로 처리됩니다.

열을 요인으로 사용하기 전에 약어에 매핑하면 실제로 성능 또한 향상됩니다. 자세한 내용은 R 및 데이터 최적화를 참조합니다.

1. 먼저 R 변수 *stateAbb* 를 만들고 다음과 같이 추가할 문자열 벡터를 정의합니다.

R 복사

```
stateAbb <- c("AK", "AL", "AR", "AZ", "CA", "CO", "CT", "DC",
    "DE", "FL", "GA", "HI","IA", "ID", "IL", "IN", "KS", "KY", "LA",
```

```
    "MA", "MD", "ME", "MI", "MN", "MO", "MS", "MT", "NB", "NC",
"ND",
    "NH", "NJ", "NM", "NV", "NY", "OH", "OK", "OR", "PA", "RI","SC",
    "SD", "TN", "TX", "UT", "VA", "VT", "WA", "WI", "WV", "WY")
```

2. 다음으로, 범주 수준(주 약어)과 기존 정수 값 간의 매핑을 지정하는 *ccColInfo* 라는 열 정보 개체를 만듭니다.

   이 문은 성별 및 카드 소유자에 대한 요인 변수도 만듭니다.

R 복사

```
ccColInfo <- list(
gender = list(
         type = "factor",
         levels = c("1", "2"),
         newLevels = c("Male", "Female")
         ),
cardholder = list(
             type = "factor",
             levels = c("1", "2"),
             newLevels = c("Principal", "Secondary")
              ),
state = list(
         type = "factor",
         levels = as.character(1:51),
         newLevels = stateAbb
         ),
balance = list(type = "numeric")
```

```
)
```

3. 업데이트된 데이터를 사용하는 SQL Server 데이터 원본을 만들려면 이전과 같이 **RxSqlServerData** 함수를 호출하되, *colInfo* 인수를 추가합니다.

R 복사

```
sqlFraudDS <- RxSqlServerData(connectionString = sqlConnString,
table = sqlFraudTable, colInfo = ccColInfo,
rowsPerRead = sqlRowsPerRead)
```

- *table* 매개변수에 대해 앞에서 만든 데이터 원본을 포함하는 *sqlFraudTable* 변수를 전달합니다.
- *colInfo* 매개변수에 대해 열 데이터 형식 및 요인 수준을 포함하는 *ccColInfo* 변수를 전달합니다.

4. 이제 **rxGetVarInfo** 함수를 사용하여 새 데이터 원본의 변수를 확인할 수 있습니다.

R 복사

```
rxGetVarInfo(data = sqlFraudDS)
```

결과

Var 1: custID, Type: integer

Var 2: gender 2 factor levels: Male Female

Var 3: state 51 factor levels: AK AL AR AZ CA ... VT WA WI WV WY

Var 4: cardholder 2 factor levels: Principal Secondary

Var 5: balance, Type: integer

Var 6: numTrans, Type: integer

Var 7: numIntlTrans, Type: integer

Var 8: creditLine, Type: integer

Var 9: fraudRisk, Type: integer

이제 지정한 변수 3 개(*gender, state, cardholder*)가 요인으로 처리됩니다.

다음 단계

계산 컨텍스트 정의 및 사용

이전 단계

RxSqlServerData 를 사용하여 SQL Server 데이터 개체 만들기

계산 컨텍스트 사용 및 정의 (SQL과 R 심층 분석)

이 문서는 데이터 과학 심층 분석 자습서를 사용 하는 방법에 대 한 일부 RevoScaleR SQL Server 와 함께 합니다.

이 단원에서는 RxInSqlServer 함수 SQL Server 에 대 한 계산 컨텍스트를 정의 하고 다음 로컬 컴퓨터 대신 서버에서 복잡 한 계산을 실행할 수 있습니다.

RevoScaleR 은 Hadoop, Spark, 또는 데이터베이스 내에서 R 코드를 실행할 수 있도록 여러 계산 컨텍스트를 지원 합니다. SQL Server 에 대 한 서버를 정의 하고 로컬 컴퓨터와 원격 실행 컨텍스트 간에 연결 및 전달 개체는 데이터베이스를 만드는 작업을 처리 하는 함수입니다.

SQL Server 를 만드는 함수를 사용 하 여 상황에 맞는 다음 정보를 계산 합니다.

- 에 대 한 연결 문자열은 SQL Server 인스턴스
- 출력 처리 방법 지정
- 추적을 사용 하거나 추적 수준을 지정 하는 선택적 인수
- 공유 데이터 디렉터리의 선택적 사양

만들기 및 계산 컨텍스트를 설정 합니다.

1. 계산이 수행 되는 인스턴스에 대 한 연결 문자열을 지정 합니다. 앞에서 만든 연결 문자열을 다시 사용할 수 있습니다. 다른 서버에는 계산을 이동 하거나 일부 작업을 수행 하는 다른 로그인을 사용 하려는 경우 다른 연결 문자열을 만들 수 있습니다.

SQL 로그인 사용

R 복사

```
sqlConnString <- "Driver=SQL Server;Server=<SQL Server instance name>; Database=<database name>;Uid=<SQL user name>;Pwd=<password>"
```

Windows 인증 사용

R 복사

```
sqlConnString <- "Driver=SQL Server;Server=instance_name;Database=DeepDive;Trusted_Connection=True"
```

2. 출력 처리 방법을 지정합니다. 다음 코드에서는 워크스테이션의 R 세션이 항상 R 작업 결과를 기다리지만, 원격 계산의 콘솔 출력을 반환하지 않도록 지정합니다.

R 복사

```
sqlWait <- TRUE

sqlConsoleOutput <- FALSE
```

RxInSqlServer 에 대한 **wait** 인수는 다음 옵션을 지원합니다.

- **TRUE**. 작업 차단으로 구성 되 고 완료 되었거나 실패 될 때까지 반환 하지 않습니다. 자세한 내용은 참조 분산 및 학습 서버 컴퓨터에에서 병렬 컴퓨팅합니다.
- **FALSE**. 작업은 비차단로 구성 및 즉시 반환 하므로 다른 R 코드 실행을 계속할 수 있습니다. 그러나 비차단 모드에서도 작업이 실행되는 동안 SQL Server 와의 클라이언트 연결을 유지해야 합니다.

3. 원격 및 로컬 R 세션에서 공유 사용을 위해 로컬 디렉터리의 위치를 지정할 수는 필요에 따라 SQL Server 컴퓨터 및 해당 계정.

R 복사

```
sqlShareDir <- paste("c:\\AllShare\\", Sys.getenv("USERNAME"),
sep="")
```

4. 공유에 대 한 특정 디렉터리를 수동으로 만들 하려는 경우에 다음과 같은 줄을 추가할 수 있습니다.

복사

```
dir.create(sqlShareDir, recursive = TRUE)
```

폴더를 공유 하는 데 현재 사용 중인을 확인 하려면 실행 `rxGetComputeContext()`, 세부 정보에 대 한 현재 계산 컨텍스트를 반환 하는 합니다. 자세한 내용은 ScaleR reference(ScaleR 참조)를 참조하세요.

5. 모든 변수를 준비 하지 제공 하 고에 대 한 인수는 **RxInSqlServer** 를 만드는 생성자는 *컨텍스트 개체를 계산*합니다.

R 복사

```
sqlCompute <- RxInSqlServer(
    connectionString = sqlConnString,
    wait = sqlWait,
    consoleOutput = sqlConsoleOutput)
```

에 대 한 구문 **RxInSqlServer** 의 거의 동일는 **RxSqlServerData** 데이터 원본을 정의 하려면 이전에 사용 하는 함수입니다. 하지만 다음과 같은 점에서 중요한 차이가 있습니다.

- RxSqlServerData 함수를 사용하여 정의한 데이터 원본 개체는 데이터가 저장되는 위치를 지정합니다.

- 함수를 사용 하 여 계산 컨텍스트를 정의 하는 반면, RxInSqlServer 집계 및 기타 계산이 수행 된 것을 표시 합니다.

  계산 컨텍스트 정의는 워크스테이션에서 수행할 수 있는 다른 모든 제네릭 R 계산에 영향을 주지 않으며 데이터의 원본을 변경하지 않습니다. 예를 들어 로컬 텍스트 파일을 데이터 원본으로 정의하지만 계산 컨텍스트를 SQL Server 로 변경하지 않고 SQL Server 컴퓨터에서 데이터에 대한 모든 읽기 및 요약을 수행할 수 있습니다.

계산 컨텍스트에서 추적을 사용 하도록 설정

때로는 작업이 로컬 컨텍스트에서 작동하지만 원격 계산 컨텍스트에서 실행될 때 문제가 발생합니다. 문제를 분석하거나 성능을 모니터링하려는 경우 계산 컨텍스트에서 추적을 사용하도록 설정하여 런타임 문제 해결을 지원할 수 있습니다.

1. 인수를 추가 하지만 동일한 연결 문자열을 사용 하 여 새 계산 컨텍스트를 만들어 *traceEnabled* 및 *traceLevel* 에 **RxInSqlServer** 생성자입니다.

R 복사

```
sqlComputeTrace <- RxInSqlServer(
    connectionString = sqlConnString,
    #shareDir = sqlShareDir,
    wait = sqlWait,
    consoleOutput = sqlConsoleOutput,
    traceEnabled = TRUE,
    traceLevel = 7)
```

이 예제에서는 *traceLevel* 속성이 7 로 설정되었으며 이는 "모든 추적 정보 표시"를 의미합니다.

2. 계산 컨텍스트를 변경하려면 rxSetComputeContext 함수를 사용하고 이름으로 컨텍스트를 지정합니다.

R 복사

```
rxSetComputeContext( sqlComputeTrace)
```

참고

이 자습서에 대 한 추적을 설정 하지 않은 계산 컨텍스트를 사용 합니다.

그러나 추적을 사용 하려는 경우 유의 경험 네트워크 연결에 의해 영향을 받을 수 있습니다. 또한 유의 해야 하는 모든 작업에 대 한 추적이 설정 된 옵션에 대 한 성능 테스트 되지 않은 때문에 있습니다.

사용 하는 방법을 알아보려면 다음 단계에서는 서버에서 R 코드를 실행 하거나 로컬 컨텍스트를 계산 합니다.

다음 단계

R 스크립트 만들기 및 실행

이전 단계

SQL Server 데이터 쿼리 및 수정

만들기 및 R 스크립트 (SQL과 R 심층 분석)를 실행 합니다.

이 문서는 데이터 과학 심층 분석 자습서를 사용 하는 방법에 대 한 일부 RevoScaleR SQL Server 와 함께 합니다.

이제 데이터 원본을 설정하고 하나 이상의 계산 컨텍스트를 설정했으므로 SQL Server 를 사용하여 몇 가지 고성능 R 스크립트를 실행할 준비가 되었습니다. 이 단원 server 계산 컨텍스트를 사용 하 여 몇 가지 일반적인 시스템 작업 학습을 수행 하려면:

- 데이터 시각화 및 몇 가지 요약 통계 생성
- 선형 회귀 모델 만들기
- 로지스틱 회귀 모델 만들기
- 새 데이터 점수 매기기 및 점수 히스토그램 만들기

계산 서버에는 컨텍스트 변경

R 코드를 실행하기 전에 *현재* 또는 *활성* 계산 컨텍스트를 지정해야 합니다.

1. R 을 사용하여 이미 정의한 계산 컨텍스트를 활성화하려면 다음과 같이 **rxSetComputeContext** 함수를 사용합니다.

R 복사

```
rxSetComputeContext(sqlCompute)
```

이 문을 실행 하는 즉시 모든 이후 계산에 진행는 SQL Server 에 지정 된 컴퓨터는 *sqlCompute* 매개 변수입니다.

2. 워크스테이션에서 R 코드를 실행하려는 경우 **local** 키워드를 사용하여 계산 컨텍스트를 다시 로컬 컴퓨터로 전환할 수 있습니다.

R 복사

```
rxSetComputeContext ("local")
```

이 함수에서 지원하는 다른 키워드 목록을 보려면 R 명령줄에서 `help("rxSetComputeContext")` 를 입력합니다.

3. 계산 컨텍스트를 지정하면 변경할 때까지 활성 상태로 유지됩니다. 그러나 원격 서버 컨텍스트에서 실행할 수 *없는* 모든 R 스크립트는 로컬로 실행됩니다.

일부 요약 통계를 계산 합니다.

계산 컨텍스트 작동 방식을 보려면 사용 하 여 일부 요약 통계를 생성을 시도 `sqlFraudDS` 데이터 원본입니다. 기억, 데이터 원본 개체에는 방금; 사용 하는 데이터 정의 계산 컨텍스트를 바뀌지 않습니다.

- 로컬로 요약을 수행 하려면 **rxSetComputeContext** 지정는 *로컬* 키워드입니다.
- SQL Server 컴퓨터에서 같은 계산을 만들려면 앞에서 정의한 SQL 계산 컨텍스트로 전환합니다.

1. 호출 된 rxSummary 함수 및 수식 및 데이터 원본 등의 필수 인수를 전달 하 고 결과 변수에 할당 `sumOut` 합니다.

R 복사

```
sumOut <- rxSummary(formula = ~gender + balance + numTrans +
numIntlTrans + creditLine, data = sqlFraudDS)
```

R 언어 여러 요약 기능을 제공 하지만 **rxSummary** 다양 한 원격 계산 컨텍스트를 포함 하 여 실행을 지원 SQL Server 합니다. 유사한 기능에 대 한 정보를 참조 하십시오. RevoScaleR 을 사용 하 여 데이터 요약합니다.

2. 처리가 완료 되는 경우의 내용을 인쇄할 수 있습니다는 `sumOut` 콘솔에 변수입니다.

R 복사

```
sumOut
```

참고

SQL Server 컴퓨터에서 결과가 반환되기 전에 결과를 출력하려고 하지 마세요. 그러지 않으면 오류가 발생할 수 있습니다.

결과

Summary Statistics Results for: ~gender + balance + numTrans +

numIntlTrans + creditLine

Data: sqlFraudDS (RxSqlServerData Data Source)

Number of valid observations: 10000

Name Mean StdDev Min Max ValidObs MissingObs

balance 4075.0318 3926.558714 0 25626 100000

numTrans 29.1061 26.619923 0 100 10000 0 100000

numIntlTrans 4.0868 8.726757 0 60 10000 0 100000

creditLine 9.1856 9.870364 1 75 10000 0 100000

성별에 대 한 범주 수

Number of categories: 2

Number of valid observations: 10000

Number of missing observations: 0

gender Counts

Male 6154

Female 3846

최대 및 최소 값 추가

계산된 요약 통계에 따라 데이터에 대한 몇 가지 유용한 정보를 발견했으며 추가 계산에 사용하기 위해 이 정보를 데이터 원본에 저장하려고 합니다. 예를 들어 히스토그램을 계산 하는 최소 및 최대 값을 사용할 수 있습니다. 이러한 이유로 추가 하 고가 및 저가 값은 **RxSqlServerData** 데이터 원본입니다.

다행히 R Services(In-Database) 범주 비율 데이터에 정수 데이터를 효율적으로 변환할 수 있는 최적화 된 기능을 포함 합니다.

1. 먼저 몇 가지 임시 변수를 설정합니다.

R 복사

```
sumDF <- sumOut$sDataFrame

var <- sumDF$Name
```

2. 앞에서 만든 `ccColInfo` 변수를 사용하여 데이터 원본의 열을 정의합니다.

또한 일부 새 계산 열을 추가 (`numTrans`, `numIntlTrans`, 및 `creditLine`)을 열 컬렉션입니다.

R 복사

```
ccColInfo <- list(
    gender = list(type = "factor",
      levels = c("1", "2"),
      newLevels = c("Male", "Female")),
    cardholder = list(type = "factor",
      levels = c("1", "2"),
      newLevels = c("Principal", "Secondary")),
    state = list(type = "factor",
      levels = as.character(1:51),
      newLevels = stateAbb),
    balance  = list(type = "numeric"),
    numTrans = list(type = "factor",
      levels = as.character(sumDF[var == "numTrans",
"Min"]:sumDF[var == "numTrans", "Max"])),
    numIntlTrans = list(type = "factor",
        levels = as.character(sumDF[var == "numIntlTrans",
"Min"]:sumDF[var =="numIntlTrans", "Max"])),
    creditLine = list(type = "numeric")
        )
```

3. 업데이트 된 버전을 만들려면 다음 문을 적용 열 컬렉션에 있는 업데이트 것은 SQL Server 앞에서 정의한 데이터 원본.

R 복사

```
sqlFraudDS <- RxSqlServerData(
    connectionString = sqlConnString,
    table = sqlFraudTable,
    colInfo = ccColInfo,
    rowsPerRead = sqlRowsPerRead)
```

`sqlFraudDS` 데이터 원본을 사용 하 여 추가 하는 새 열이 포함 이제 `ccColInfo` 합니다.

수정만 R;에서 데이터 원본 개체에 영향을 줄이 시점에서 새 데이터가 아직 데이터베이스 테이블에 기록 된 했습니다. 그러나에서 수집 된 데이터를 사용할 수는 `sumOut` 변수를 시각화 및 요약을 만듭니다. 다음 단계 계산 컨텍스트를 전환 하는 동안이 작업을 수행 하는 방법에 설명 합니다.

팁

사용 하는 계산 컨텍스트를 잊은 경우 실행 `rxGetComputeContext()`합니다. 반환 값이 "RxLocalSeq 계산 컨텍스트" 로컬 계산 컨텍스트에서 실행을 나타냅니다.

다음 단계

R 을 사용하여 SQL Server 데이터 시각화

이전 단계

계산 컨텍스트 정의 및 사용

R (SQL과 R 심층 분석)를 사용하 여 SQL Server 데이터를 시각화 합니다.

이 문서는 데이터 과학 심층 분석 자습서를 사용 하는 방법에 대 한 일부 RevoScaleR SQL Server 와 함께 합니다.

R Services(In-Database) 의 향상된 패키지에는 확장성과 병렬 처리에 최적화된 여러 함수가 포함되어 있습니다. 일반적으로 이러한 함수 앞에는 **rx** 또는 **Rx** 가 붙습니다.

이 연습에서는 사용는 **rxHistogram** 함수에서 값의 분포를 볼 수는 *creditLine* 성별 열입니다.

RxHistogram 를 사용 하 여 데이터 시각화

1. 다음 R 코드를 사용하여 rxHistogram 함수를 호출하고 수식 및 데이터 원본을 전달합니다. 처음에 이 코드를 로컬로 실행하여 예상 결과 및 걸리는 시간을 확인할 수 있습니다.

R 복사

```
rxHistogram(~creditLine|gender, data = sqlFraudDS,  histType =
"Percent")
```

내부적으로 **rxHistogram** 은 RevoScaleR 패키지에 포함된 **rxCube** 함수를 호출합니다. **rxCube** 계산 열 수식에 지정 된 각 변수에 대 한 열이 포함 된 단일 목록 (또는 데이터 프레임)을 출력 합니다.

2. 이제 원격 SQL Server 컴퓨터에 계산 컨텍스트를 설정 하 고 실행 **rxHistogram** 다시 합니다.

R 복사

```
rxSetComputeContext(sqlCompute)
```

3. 같은 데이터 원본을 사용하므로 결과는 정확히 같지만, 계산은 SQL Server 컴퓨터에서 수행됩니다. 그런 다음 결과가 로컬 워크스테이션에 반환되어 그려집니다.

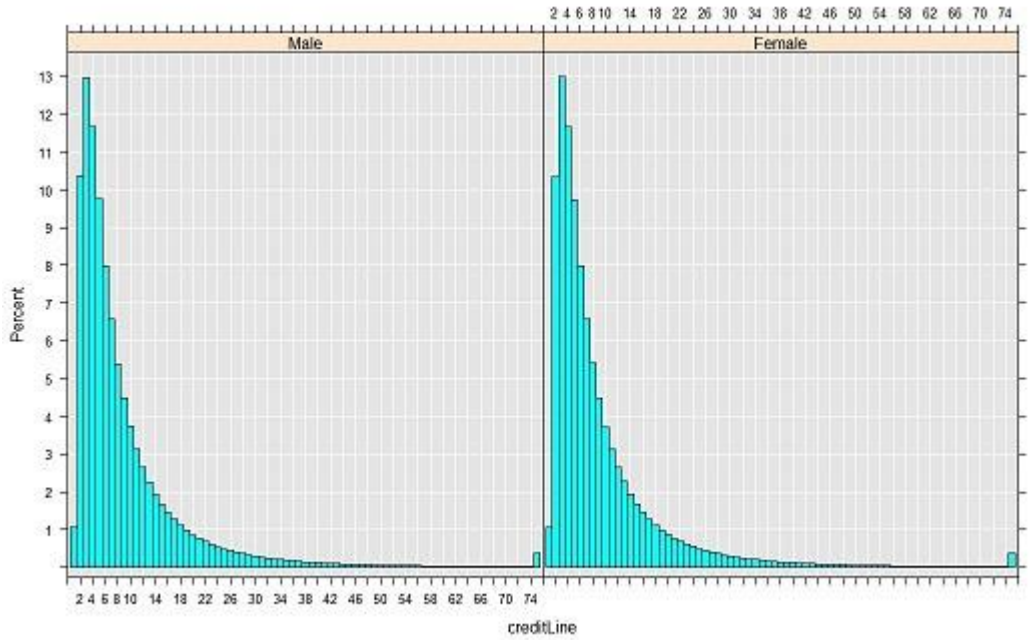

1. 호출할 수도 있습니다는 **rxCube** 함수 및 함수를 그래프에 표시 되는 R 에 결과 전달 합니다. 예를 들어 다음 예제에서는 **rxCube** 를 사용하여 *numTrans* 및 *numIntlTrans* 의 모든 조합에 대해 *fraudRisk* 의 평균을 계산합니다.

R 복사

```
cube1 <- rxCube(fraudRisk~F(numTrans):F(numIntlTrans),  data =
sqlFraudDS)
```

그룹 평균을 계산하는 데 사용되는 그룹을 지정하려면 `F()` 표기법을 사용합니다. 이 예제에서는 `F(numTrans):F(numIntlTrans)` 나타냅니다 변수에 정수 `_numTrans` 및 `numIntlTrans` 각 정수 값에 대 한 수준으로 범주 변수로 처리 해야 합니다.

낮은 임계값과 높은 수준의 데이터 원본에 이미 추가 된 때문에 `sqlFraudDS` (사용 하는 `colInfo` 매개 변수), 수준 히스토그램에 자동으로 사용 됩니다.

2. 기본 반환 값의 **rxCube** 는 *rxCube 개체*, 교차 집계를 나타냅니다. 그러나 rxResultsDF 함수를 사용하여 R 의 표준 그리기 함수 중 하나에서 쉽게 사용할 수 있는 데이터 프레임으로 결과를 변환할 수 있습니다.

R 복사

```
cubePlot <- rxResultsDF(cube1)
```

rxCube 함수는 선택적 인수를 포함 *returnDataFrame* = **TRUE**, 하는 직접 결과 데이터 프레임으로 변환 하는 데 사용할 수 없습니다. 예를 들어 다음과 같이 사용할 수 있습니다.

`print(rxCube(fraudRisk~F(numTrans):F(numIntlTrans), data = sqlFraudDS, returnDataFrame = TRUE))`

그러나 **rxResultsDF** 출력이 훨씬 더 명확하며 원본 열의 이름을 유지합니다.

3. 사용 하 여 열 지도 만들려면 다음 코드를 실행 하는 마지막으로 `levelplot` 에서 함수는 **격자** 모든 R 배포에 포함 되어 있는 패키지입니다.

R 복사

```
levelplot(fraudRisk~numTrans*numIntlTrans, data = cubePlot)
```

결과

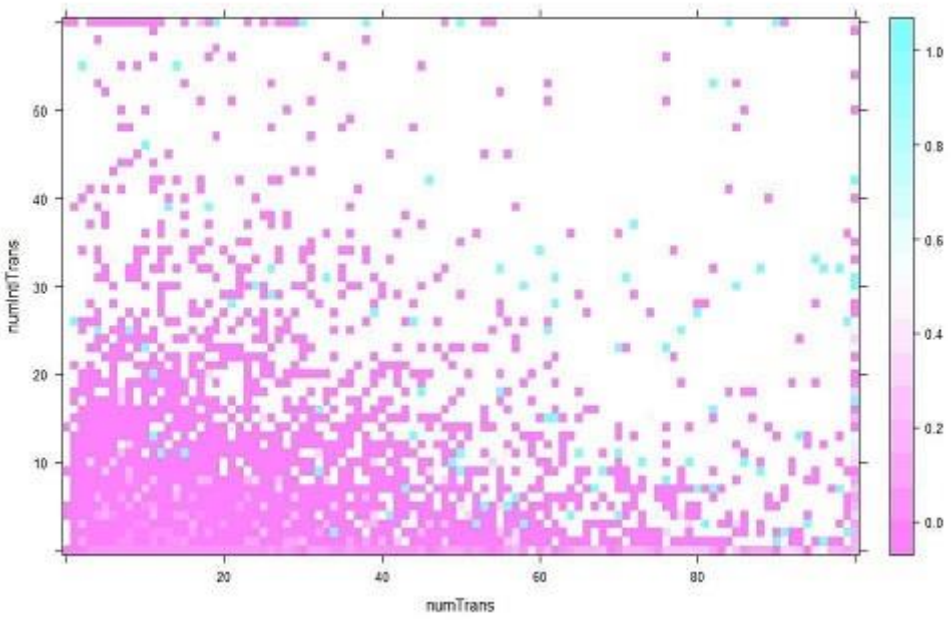

이 빠른 분석에서도 트랜잭션 수와 국제 트랜잭션 수 둘 다에서 사기 위험이 증가하는 것을 확인할 수 있습니다.

에 대 한 자세한 내용은 **rxCube** 함수와 크로스탭 일반적으로 참조 RevoScaleR 을 사용 하 여 데이터 요약합니다.

다음 단계

SQL Server 데이터를 사용 하 여 R 모델 만들기

이전 단계

R 스크립트 만들기 및 실행

R 모델 (SQL 과 R 심층 분석)을 만들으십시오

이 문서는 데이터 과학 심층 분석 자습서를 사용 하는 방법에 대 한 일부 RevoScaleR SQL Server 와 함께 합니다.
이제 교육 데이터를 보강했으므로 선형 회귀를 사용하여 데이터를 분석해야 합니다. 선형 모델은 예측 분석 분야의 중요한 도구이며, **의** RevoScaleR R Services(In-Database) 패키지에는 확장성 있는 고성능 알고리즘이 포함되어 있습니다.

선형 회귀 모델 만들기

이 단계에 있는 값의 독립 변수로 사용 하 여 고객에 대 한 신용 카드 잔액을 예측 하는 간단한 선형 모델을 만듭니다는 *성별* 및 *creditLine* 열입니다.
이 위해 사용 하 여는 rxLinMod 원격 계산 컨텍스트를 지 원하는 함수입니다.

1. 완료 된 저장 하는 R 변수를 만들 모델 및 호출 **rxLinMod**, 적절 한 수식 전달 합니다.

   R 복사

   ```
   linModObj <- rxLinMod(balance ~ gender + creditLine,  data = sqlFraudDS)
   ```

2. 표준 R 을 호출 하는 결과의 요약을 보려면 `summary` 모델 개체에 대해 함수입니다.

   R 복사

   ```
   summary(linModObj)
   ```

일반 R 함수 등의 특이 한 생각할 수 있습니다 `summary` 이전 단계에서 서버에 계산 컨텍스트를 설정 하므로 여기에서 작동할 것입니다. 그러나 **rxLinMod** 함수는 원격 계산 컨텍스트를 사용하여 모델을 만들더라도 로컬 워크스테이션에 대한 모델을 포함하고 이를 공유 디렉터리에 저장하는 개체도 반환합니다.
따라서 "로컬" 컨텍스트를 사용하여 만들어진 것처럼 모델에 대해 표준 R 명령을 실행할 수 있습니다.

결과

복사

```
Linear Regression Results for: balance ~ gender + creditLineData: sqlFraudDS
(RxSqlServerData Data Source)

Dependent variable(s): balance

Total independent variables: 4 (Including number dropped: 1)

Number of valid observations: 10000

Number of missing observations: 0

Coefficients: (1 not defined because of singularities)



Estimate Std. Error t value Pr(>|t|) (Intercept)

3253.575 71.194 45.700 2.22e-16

gender=Male -88.813 78.360 -1.133 0.257

gender=Female Dropped Dropped Dropped Dropped

creditLine 95.379 3.862 24.694 2.22e-16

Signif. codes: 0  0.001  0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1



Residual standard error: 3812 on 9997 degrees of freedom

Multiple R-squared: 0.05765

Adjusted R-squared: 0.05746

F-statistic: 305.8 on 2 and 9997 DF, p-value: < 2.2e-16

Condition number: 1.0184
```

로지스틱 회귀 모델 만들기

다음으로, 특정 고객 사기 위험 인지 여부를 나타내는 로지스틱 회귀 모델을 만듭니다. 사용 하 여는 **RevoScaleR** rxLogit 계산 컨텍스트는 원하는 맞춤 원격에 로지스틱 회귀 모델의 함수입니다.

1. 계산 컨텍스트를 그대로 유지합니다. 또한 계속해서 같은 데이터 원본을 사용합니다.

2. **rxLogit** 함수를 호출하고 모델을 정의하는 데 필요한 수식을 전달합니다.

R 복사

```
logitObj <- rxLogit(fraudRisk ~ state + gender + cardholder + balance +
numTrans + numIntlTrans + creditLine, data = sqlFraudDS, dropFirst =
TRUE)
```

삭제된 더미 변수 3 개를 비롯하여 60 개의 독립 변수를 포함하는 큰 모델이기 때문에 계산 컨텍스트에서 개체가 반환될 때까지 잠시 기다려야 할 수도 있습니다.

모델이 이렇게 큰 이유는 R 및 **RevoScaleR** 패키지에서 모든 수준의 범주 요인 변수가 자동으로 별도의 더미 변수로 처리되기 때문입니다.

3. 반환 된 모델의 요약을 확인 하려면 R 을 호출 `summary` 함수입니다.

R 복사

```
summary(logitObj)
```

일부 결과

복사

```
Logistic Regression Results for: fraudRisk ~ state + gender + cardholder +
balance + numTrans + numIntlTrans + creditLine

Data: sqlFraudDS (RxSqlServerData Data Source)

Dependent variable(s): fraudRisk

Total independent variables: 60 (Including number dropped: 3)

Number of valid observations: 10000 -2



LogLikelihood: 2032.8699 (Residual deviance on 9943 degrees of freedom)



Coefficients:

Estimate Std. Error z value Pr(>|z|)     (Intercept)
```

```
-8.627e+00  1.319e+00  -6.538 6.22e-11
state=AK                Dropped    Dropped Dropped  Dropped
state=AL             -1.043e+00  1.383e+00  -0.754   0.4511

(other states omitted)

gender=Male             Dropped    Dropped Dropped  Dropped
gender=Female         7.226e-01  1.217e-01   5.936 2.92e-09
cardholder=Principal    Dropped    Dropped Dropped  Dropped
cardholder=Secondary  5.635e-01  3.403e-01   1.656   0.0977
balance               3.962e-04  1.564e-05  25.335 2.22e-16
numTrans              4.950e-02  2.202e-03  22.477 2.22e-16
numIntlTrans          3.414e-02  5.318e-03   6.420 1.36e-10
creditLine            1.042e-01  4.705e-03  22.153 2.22e-16

Signif. codes:  0 ‘\*\*\*’ 0.001 ‘\*\*’ 0.01 ‘\*’ 0.05 ‘.’ 0.1 ‘ ’ 1
Condition number of final variance-covariance matrix: 3997.308
Number of iterations: 15
```

다음 단계

새 데이터 점수

새 데이터 (SQL 과 R 심층 분석) 점수를 매깁니다.

이 문서는 데이터 과학 심층 분석 자습서를 사용 하는 방법에 대 한 일부 RevoScaleR SQL Server 와 함께 합니다.

이 단계에서는 앞에서 만든 입력으로 동일한 독립 변수를 사용 하는 다른 데이터 세트에 대 한 점수를 작성 하는 로지스틱 회귀 모델을 사용 합니다.

참고

다음이 단계 중 일부에 대 한 DDL 관리자 권한이 필요합니다.

생성 하 고 점수를 저장 합니다.

1. 이전에 설정 하는 데이터 원본을 업데이트 `sqlScoreDS`, 필요한 열 정보를 추가 합니다.

R 복사

```
sqlScoreDS <- RxSqlServerData(
    connectionString = sqlConnString,
    table = sqlScoreTable,
    colInfo = ccColInfo,
    rowsPerRead = sqlRowsPerRead)
```

2. 결과 손실 하지 않으려면 하 게 하려면 새 데이터 원본 개체를 만듭니다. 그런 다음 새 데이터 원본 개체를 사용 하 여 새 테이블에 채우기는 SQL Server 데이터베이스입니다.

R 복사

```
sqlServerOutDS <- RxSqlServerData(table = "ccScoreOutput",
    connectionString = sqlConnString,
    rowsPerRead = sqlRowsPerRead )
```

이때 테이블은 만들어지지 않았습니다. 이 문은 데이터의 컨테이너를 정의할 뿐입니다.

3. 현재 계산 컨텍스트를 확인하고, 필요한 경우 계산 컨텍스트를 서버로 설정합니다.

R 복사

```
rxSetComputeContext(sqlCompute)
```

4. 결과를 생성하는 예측 함수를 실행하기 전에 기존 출력 테이블이 있는지 확인해야 합니다. 그렇지 않으면 새 테이블을 작성 하려고 할 때 오류가 발생할 것 있습니다.

이렇게 하려면 **rxSqlServerTableExists** 및 **rxSqlServerDropTable** 함수를 호출하여 테이블 이름을 입력으로 전달합니다.

R 복사

```
if (rxSqlServerTableExists("ccScoreOutput"))
rxSqlServerDropTable("ccScoreOutput")
```

- **rxSqlServerTableExists** 함수는 ODBC 드라이버를 쿼리하고, 테이블이 있으면 TRUE 를 반환하고 없으면 FALSE 를 반환합니다.
- 함수 **rxSqlServerDropTable** DDL 을 실행 하 고 TRUE 테이블이 있는 경우 성공적으로 삭제 FALSE 그렇지 않으면 반환 합니다.
- 두 함수를 볼 수 있습니다에 대 한 참조: rxSqlServerDropTable

5. 사용할 준비가 되었습니다. 이제는 rxPredict 함수를 점수를 생성 하 고 데이터 원본에 정의 된 새 테이블에 저장할 `sqlScoreDS` 합니다.

R 복사

```
rxPredict(modelObject = logitObj,
    data = sqlScoreDS,
    outData = sqlServerOutDS,
    predVarNames = "ccFraudLogitScore",
      type = "link",
    writeModelVars = TRUE,
    overwrite = TRUE)
```

rxPredict 함수는 원격 계산 컨텍스트에서의 실행을 지원하는 또 다른 함수입니다. **rxPredict** 함수를 사용하여 rxLinMod, rxLogit 또는 rxGlm 을 통해 만든 모델에서 점수를 만들 수 있습니다.

- 여기서는 *writeModelVars* 매개 변수가 **TRUE** 로 설정되었습니다. 이 경우 예측에 사용된 변수가 새 테이블에 포함됩니다.
- *predVarNames* 매개 변수는 결과를 저장할 변수를 지정합니다. 새 변수를 전달하는 여기 `ccFraudLogitScore` 합니다.
- *rxPredict* 에 대한 **type** 매개 변수는 예측 계산 방법을 정의합니다. 키워드 지정 **응답** 응답 변수의 배율에 따라 점수를 생성 합니다. 키워드를 사용 또는 **링크** 는

쿼리에서 기본 링크 함수에 따라 점수를 생성할 예측 로지스틱 눈금을 사용 하여 생성 됩니다.

6. 잠시 후 Management Studio 에서 테이블 목록을 새로 고쳐 새 테이블 및 해당 데이터를 확인할 수 있습니다.
7. 출력 예측에 변수를 더 추가하려면 *extraVarsToWrite* 인수를 사용합니다. 예를 들어 다음 코드에서는 변수에서에서 `custID` 점수 매기기 데이터 테이블에서 예측의 출력 테이블에 추가 됩니다.

R 복사

```
rxPredict(modelObject = logitObj,
       data = sqlScoreDS,
       outData = sqlServerOutDS,
       predVarNames = "ccFraudLogitScore",
         type = "link",
       writeModelVars = TRUE,
       extraVarsToWrite = "custID",
       overwrite = TRUE)
```

히스토그램에 표시 점수

새 테이블을 만든 후 계산 표시 하는 10,000 예측 점수 막대 그래프. 낮은 임계값과 높은 값을 지정 하므로 데이터베이스에서 해당 권한을 받아야, 경우 작업 데이터에 추가할 계산이 빠릅니다.

1. 새 데이터 원본을 만들고 `sqlMinMax`, 낮은 임계값과 높은 값을 가져올 데이터베이스를 쿼리 하는 합니다.

R 복사

```
sqlMinMax <- RxSqlServerData(
    sqlQuery = paste("SELECT MIN(ccFraudLogitScore) AS minVal,",
    "MAX(ccFraudLogitScore) AS maxVal FROM ccScoreOutput"),
    connectionString = sqlConnString)
```

이 예제에서는 **RxSqlServerData** 데이터 원본 개체를 사용하여 SQL 쿼리, 함수 또는 저장 프로시저를 기반으로 임의 데이터 세트를 정의한 다음 이를 R 코드에서 사용하기가 얼마나 쉬운지를 확인할 수 있습니다. 변수는 실제 값을 저장하는 것이 아니라 데이터 원본 정의를 저장할 뿐입니다. 쿼리는 **rxImport** 와 같은 함수에서 변수를 사용할 때만 실행되어 값을 생성합니다.

2. 호출 된 rxImport 계산 컨텍스트 간에 공유할 수 있는 데이터 프레임의 끝에 있는 함수입니다.

R 복사

```
minMaxVals <- rxImport(sqlMinMax)
minMaxVals \<- as.vector(unlist(minMaxVals))
```

결과

> *minMaxVals*

[1] -23.970256 9.786345

3. 이제는 최대값과 최소값을 사용할 수 값을 사용 하 여 생성 된 점수에 대 한 다른 데이터 소스를 만듭니다.

R 복사

```
sqlOutScoreDS <- RxSqlServerData(sqlQuery = "SELECT
ccFraudLogitScore FROM ccScoreOutput",
    connectionString = sqlConnString,
```

```
    rowsPerRead = sqlRowsPerRead,
        colInfo = list(ccFraudLogitScore = list(
            low = floor(minMaxVals[1]),
                    high = ceiling(minMaxVals[2]) ) ) )
```

4. 데이터 원본 개체를 사용 하 여 `sqlOutScoreDS` 하는 점수를 얻을 계산 하 고 막대 그래프를 표시 합니다. 필요한 경우 계산 컨텍스트를 설정하는 코드를 추가합니다.

R 복사

```
# rxSetComputeContext(sqlCompute)
rxHistogram(~ccFraudLogitScore, data = sqlOutScoreDS)
```

결과

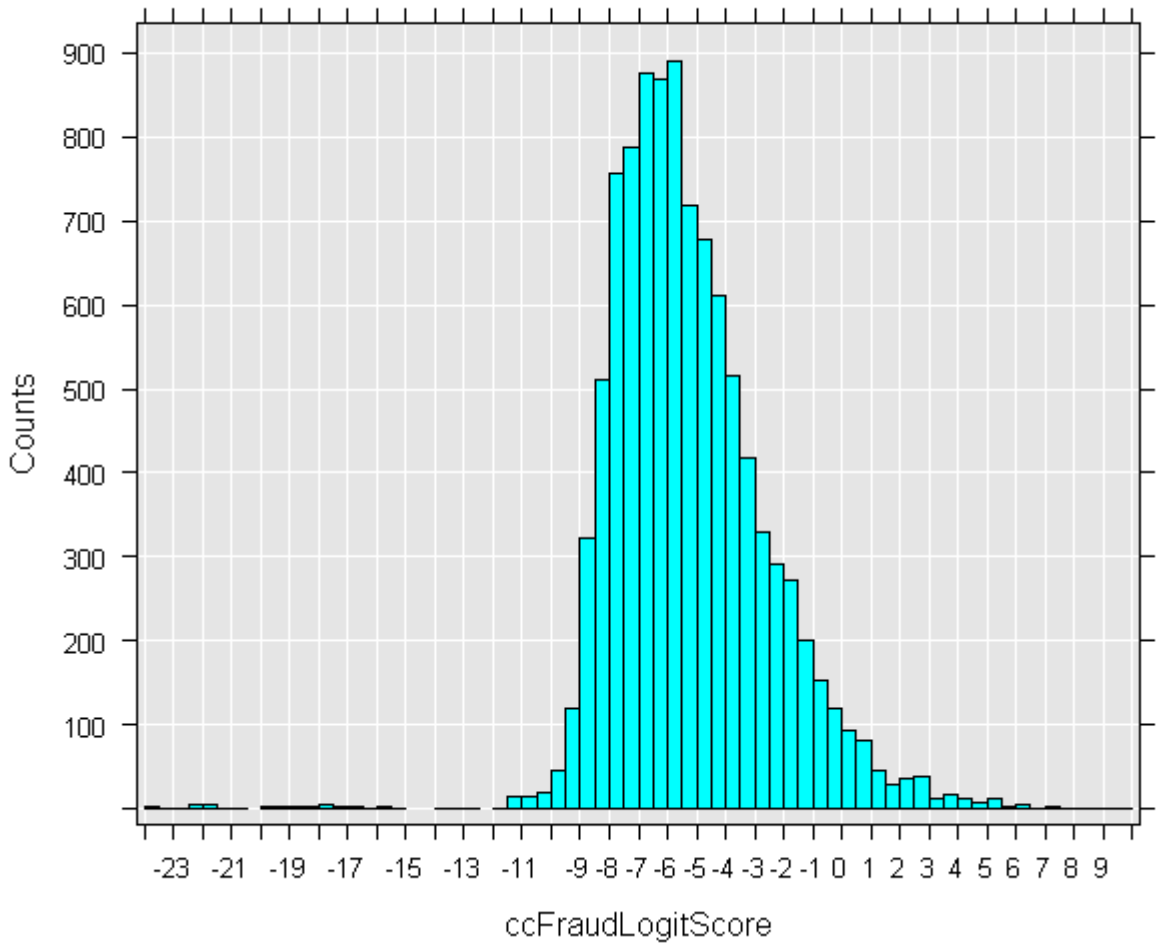

다음 단계

R 을 사용하여 데이터 변환

이전 단계

모델 만들기

R (SQL 과 R 심층 분석)를 사용하 여 데이터를 변환 합니다.

이 문서는 데이터 과학 심층 분석 자습서를 사용 하는 방법에 대 한 일부 RevoScaleR SQL Server 와 함께 합니다.

RevoScaleR 패키지는 다양한 분석 단계에서 데이터를 변환하기 위한 여러 함수를 제공합니다.

- **rxDataStep** 은 데이터 하위 세트를 만들고 변환하는 데 사용할 수 있습니다.
- **rxImport** 는 XDF 파일 또는 메모리 내 데이터 프레임으로 또는 그 반대로 데이터를 가져올 때 데이터 변환을 지원합니다.
- 특별히 데이터 이동에 사용되지는 않지만 **rxSummary**, **rxCube**, **rxLinMod** 및 **rxLogit** 함수도 모두 데이터 변환을 지원합니다.

이 섹션에서는 이러한 함수를 사용 하는 방법을 설명 합니다. 부터 시작 하겠습니다 rxDataStep 합니다.

RxDataStep 를 사용 하 여 변수를 변환

rxDataStep 함수는 하나의 데이터 원본에서 읽어 다른 데이터 원본에 쓰면서 한 번에 하나씩 데이터 청크를 처리합니다. 변환할 열, 로드할 변환 등을 지정할 수 있습니다.

효과적으로 만들기 위해이 예에서는, 데이터를 변형 다른 R 패키지의 함수를 사용 하겠습니다. **boot** 패키지는 "권장" 패키지 중 하나이므로, **boot** 는 R 의 모든 배포에 포함되지만 시작할 때 자동으로 로드되지 않습니다. 따라서 SQL Server 와

함께 사용 중인 R Services(In-Database)인스턴스에서 패키지를 이미 사용할 수 있어야 합니다.

부팅 함수를 사용 하 여, 패키지 `inv.logit`는 logit 의 역 수를 계산 합니다. 즉, `inv.logit` 함수는 로짓을 다시 [0,1] 눈금의 확률로 변환합니다.

팁

이 규모에 맞게 예측을 가져오는 다른 방법을 설정 하는 것은 *형식* 매개 변수를 **응답** rxPredict 원래 호출에 합니다.

1. 테이블에 데이터를 저장할 데이터 소스를 만들어 시작 `ccScoreOutput`합니다.

R 복사

```
sqlOutScoreDS <- RxSqlServerData( table =  "ccScoreOutput",
connectionString = sqlConnString, rowsPerRead = sqlRowsPerRead )
```

2. 다른 데이터 소스 테이블에 대 한 데이터를 저장할 추가 `ccScoreOutput2`합니다.

R 복사

```
sqlOutScoreDS2 <- RxSqlServerData( table =  "ccScoreOutput2",
connectionString = sqlConnString, rowsPerRead = sqlRowsPerRead )
```

새 테이블에는 이전 모든 변수를 저장 `ccScoreOutput` 테이블 및 새로 만든된 변수에 합니다.

3. 계산 컨텍스트를 SQL Server 인스턴스로 설정합니다.

R 복사

```
rxSetComputeContext(sqlCompute)
```

4. 함수를 사용 하 여 **rxSqlServerTableExists** 확인 하려면 있는지 여부를 출력 테이블 `ccScoreOutput2` 이미; 있으며이 경우 함수를 사용 **rxSqlServerDropTable** 는 테이블을 삭제 합니다.

R 복사

```
if (rxSqlServerTableExists("ccScoreOutput2"))
rxSqlServerDropTable("ccScoreOutput2")
```

5. **rxDataStep** 함수를 호출하고 목록에서 원하는 변환을 지정합니다.

R 복사

```
rxDataStep(inData = sqlOutScoreDS,
    outFile = sqlOutScoreDS2,
    transforms = list(ccFraudProb = inv.logit(ccFraudLogitScore)),
    transformPackages = "boot",
    overwrite = TRUE)
```

각 열에 적용되는 변환을 정의할 때 변환에 필요한 추가 R 패키지를 지정할 수도 있습니다. 변환을 수행할 수 있는 형식에 대한 자세한 내용은 RevoScaleR 을 사용하여 데이터를 변환 및 부분 집합 방법을 참조합니다.

6. **rxGetVarInfo** 를 호출하여 새 데이터 세트의 변수 요약을 확인합니다.

R 복사

```
rxGetVarInfo(sqlOutScoreDS2)
```

결과

Var 1: ccFraudLogitScore, Type: numeric

Var 2: state, Type: character

Var 3: gender, Type: character

Var 4: cardholder, Type: character

Var 5: balance, Type: integer

Var 6: numTrans, Type: integer

Var 7: numIntlTrans, Type: integer

Var 8: creditLine, Type: integer

Var 9: ccFraudProb, Type: numeric

원래 로짓 점수는 유지되지만 새 열 *ccFraudProb* 가 추가되어 로짓 점수가 0 과 1 사이의 값으로 표시됩니다.

테이블에 기록 된 비율 변수는 `ccScoreOutput2` 문자 데이터로 합니다. 이후 분석에서 요인으로 사용하려면 *colInfo* 매개 변수를 사용하여 수준을 지정합니다.

다음 단계

rxImport 를 사용하여 메모리에 데이터 로드

이전 단계

R 스크립트 만들기 및 실행

RxImport (SQL 과 R 심층 분석)를 사용 하 여 메모리에 데이터 로드

이 문서는 데이터 과학 심층 분석 자습서를 사용 하는 방법에 대 한 일부 RevoScaleR SQL Server 와 함께 합니다.
rxImport 데이터 프레임에서 세션 메모리 나 디스크에 있는 XDF 파일에 데이터 원본에서 데이터를 이동 하는 함수를 사용할 수 있습니다. 파일을 대상으로 지정하지 않으면 데이터는 메모리에 데이터 프레임으로 저장됩니다.
이 단계에서 데이터를 가져오는 방법을 배웁니다 SQL Server 를 사용 하 여는 **rxImport** 관심 있는 데이터는 로컬 파일에 추가 하는 함수입니다. 이렇게 하면 데이터베이스를 다시 쿼리하지 않고도 로컬 계산 컨텍스트에서 반복하여 데이터를 분석할 수 있습니다.

SQL Server 에서 로컬 메모리에 데이터의 하위 세트를 추출

자세히 위험 수준이 높은 개인만 검사할 것인지 결정 합니다. 원본 테이블에 SQL Server 크므로 방금 위험 수준이 높은 고객에 대 한 정보를 가져오려는 합니다. 그런 다음 로컬 워크스테이션의 메모리에 데이터 프레임으로 해당 데이터를 로드 합니다.

1. 계산 컨텍스트를 로컬 워크스테이션으로 다시 설정합니다.

   R 복사

   ```
   rxSetComputeContext("local")
   ```

2. *sqlQuery* 매개 변수에 유효한 SQL 문을 제공하는 새 SQL Server 데이터 원본 개체를 만듭니다. 이 예제에서는 위험 점수가 가장 높은 관찰의 하위 세트를 가져옵니다. 이렇게 하면 필요한 데이터만 로컬 메모리에 저장됩니다.

   R 복사

```
sqlServerProbDS \<- RxSqlServerData(

    sqlQuery = paste("SELECT * FROM ccScoreOutput2",

    "WHERE (ccFraudProb > .99)"),

    connectionString = sqlConnString)
```

3. 함수 호출 rxImport 로컬 R 세션에서 데이터 프레임으로 데이터를 읽을 수 있습니다.

   R 복사

```
highRisk <- rxImport(sqlServerProbDS)
```

   작업에 성공 하면 다음과 같은 상태 메시지가 나타납니다: "Rows Read: 35, 총 행 처리 됨: 35, 총 청크 시간: 0.036 시간 (초)"

4. 메모리 내 데이터 프레임에서 위험 수준이 높은 관찰 인 했으므로 데이터 프레임을 조작 하기 위한 다양 한 R 함수를 사용할 수 있습니다. 예를 들어 해당 위험 점수 고객 주문 수 있으며 가장 높은 위험 노출 하는 고객의 목록을 인쇄.

   R 복사

```
orderedHighRisk <- highRisk[order(-highRisk$ccFraudProb),]

row.names(orderedHighRisk) <- NULL

head(orderedHighRisk)
```

결과

ccFraudLogitScore state gender cardholder balance numTrans numIntlTrans creditLine ccFraudProb1
9.786345 SD Male Principal 23456 25 5 75 0.99994382
9.433040 FL Female Principal 20629 24 28 75 0.99992003
8.556785 NY Female Principal 19064 82 53 43 0.99980784
8.188668 AZ Female Principal 19948 29 0 75 0.99972235
7.551699 NY Female Principal 11051 95 0 75 0.99947516
7.335080 NV Male Principal 21566 4 6 75 0.9993482

rxImport 대한 자세한 정보

rxImport 를 사용하여 데이터 이동은 물론 데이터를 읽는 동안 데이터를 변환할 수도 있습니다. 예를 들어 고정 너비 열에 대해 문자 수를 지정하고, 변수에 대한 설명을 제공하고, 요인 열에 대한 수준을 설정하고, 가져온 후 사용할 새로운 수준을 만들 수 있습니다.
rxImport 함수 가져오기 프로세스 동안 열에 변수 이름을 할당 하지만 사용 하여 새 변수 이름을 지정할 수 있습니다는 *colInfo* 매개 변수 또는 를사용하여변경데이터형식 *colClasses* 매개 변수입니다.
transforms 매개 변수에서 추가 작업을 지정하여 읽은 각 데이터 청크에 대한 기본 처리를 수행할 수 있습니다.

다음 단계

rxDataStep 을 사용하여 새 SQL Server 테이블 만들기

이전 단계

R 을 사용하여 데이터 변환

RxDataStep (SQL 과 R 심층 분석)를 사용 하 여 새 SQL Server 테이블 만들기

이 문서는 데이터 과학 심층 분석 자습서를 사용 하는 방법에 대 한 일부 RevoScaleR SQL Server 와 함께 합니다.

이 단원에서는 메모리 내 데이터 프레임 간에 데이터를 이동 하는 방법을 배웁니다는 SQL Server 컨텍스트와 로컬 파일입니다.

참고

이 단원에서는 다른 데이터 세트를 사용 합니다. 항공편 지연 데이터 세트는 머신 러닝 실험에 널리 사용 되는 공용 데이터 세트입니다. 이 예에서 사용 된 데이터 파일은 다른 제품 예제와 동일한 디렉터리에서 사용할 수 있습니다.

로컬 데이터에서 SQL Server 테이블 만들기

이 자습서의 앞부분에서 사용한는 **RxTextData** 텍스트 파일에서 R 로 데이터를 가져오려면 작동 하 고 다음 사용는 **RxDataStep** 함수에 데이터를 이동 하려면 SQL Server 합니다.

이 단원에는 다른 방법을 사용 하 고 파일에서 사용 하 여 데이터에 저장 된 XDF 형식합니다. 변환 된 데이터 형식의 새 파일에 저장 하면 XDF 파일을 사용

하 여 데이터에 대 한 몇 가지 간단한 변형 작업을 수행한 후 SQL Server 테이블입니다.

XDF 소식

XDF 형식이 고 차원 데이터에 대 한 개발 하는 XML 표준 및에서 사용 하는 네이티브 파일 형식 컴퓨터 학습 서버합니다. 또한 행 및 열 처리와 분석을 최적화하는 R 인터페이스가 포함된 이진 파일 형식입니다. XDF 형식을 사용하여 데이터를 이동하고 분석에 유용한 데이터의 하위 세트를 저장할 수 있습니다.

1. 계산 컨텍스트를 로컬 워크스테이션으로 설정합니다. **이 단계에 대 한 DDL 권한이 필요 합니다.**

복사

```R
rxSetComputeContext("local")
```

1. **RxXdfData** 함수를 사용하여 새 데이터 원본 개체를 정의합니다. XDF 데이터 소스를 정의 하려면 데이터 파일의 경로를 지정 합니다.

텍스트 변수를 사용 하 여 파일의 경로를 지정할 수 있습니다. 그러나,이 경우에 사용 하는 편리한 바로 가기는 **rxGetOption** 작동 하 고 샘플 데이터 디렉터리에서 파일 (AirlineDemoSmall.xdf)을 가져옵니다.

R 복사

```
xdfAirDemo <- RxXdfData(file.path(rxGetOption("sampleDataDir"),
"AirlineDemoSmall.xdf"))
```

2. 메모리 내 데이터에서 rxGetVarInfo 를 호출하여 데이터 세트 요약을 확인합니다.

R 복사

```
rxGetVarInfo(xdfAirDemo)
```

결과

Var 1: ArrDelay, Type: integer, Low/High: (-86, 1490)

Var 2: CRSDepTime, Type: numeric, Storage: float32, Low/High: (0.0167, 23.9833)

Var 3: DayOfWeek 7 factor levels: Monday Tuesday Wednesday Thursday Friday Saturday Sunday

참고

XDF 파일로 데이터를 로드하기 위해 다른 함수를 호출할 필요가 없으며 데이터에서 즉시 **rxGetVarInfo** 를 호출할 수 있다는 사실을 알아차리셨나요? XDF 가 RevoScaleR 에 대한 기본 임시 저장 방법이기 때문입니다. XDF 파일 외에 **rxGetVarInfo** 함수에는 이제 다양 한 원본 형식을 지원 합니다.

1. 이 데이터를 넣기는 SQL Server 테이블, 저장 *DayOfWeek* 으로 정수 1 ~ 7 사이의 값입니다.

   이렇게 하려면 먼저 SQL Server 데이터 원본을 정의합니다.

   R 복사

```
sqlServerAirDemo <- RxSqlServerData(table = "AirDemoSmallTest",
connectionString = sqlConnString)
```

2. 이름이 같은 테이블이 이미 있는지 확인하고, 있을 경우 테이블을 삭제합니다.

   R 복사

```
if (rxSqlServerTableExists("AirDemoSmallTest",  connectionString =
sqlConnString))  rxSqlServerDropTable("AirDemoSmallTest",
connectionString = sqlConnString)
```

3. 테이블을 만들고 **rxDataStep** 에 대한 다양한 제품 샘플에서 사용되므로 테스트를 위해 보관해 두면 유용합니다. 이 함수는 두 데이터에서 이미 데이터 원본을 정의 하 고 전달 되는 도중 데이터를 선택적으로 변환할 수를 이동 합니다.

R 복사

```
rxDataStep(inData = xdfAirDemo, outFile = sqlServerAirDemo,
       transforms = list( DayOfWeek = as.integer(DayOfWeek),
       rowNum = .rxStartRow : (.rxStartRow + .rxNumRows - 1) ),
       overwrite = TRUE )
```

이 테이블은 매우 크기 때문에 테이블, 하므로이 이와 같은 최종 상태 메시지가 표시 될 때까지 기다렸다가: *Rows Read: 200000, 총 행이 처리: 600000* 합니다.

4. 계산 컨텍스트를 SQL Server 컴퓨터로 다시 설정합니다.

R 복사

```
rxSetComputeContext(sqlCompute)
```

5. 새 테이블에서 간단한 SQL 쿼리를 사용하여 새 SQL Server 데이터 원본을 만듭니다. 이 정의 대 한 계수 수준을 추가 *DayOfWeek* 열을 사용 하는 *colInfo* 인수를 **RxSqlServerData** 합니다.

R 복사

```
SqlServerAirDemo <- RxSqlServerData(
    sqlQuery = "SELECT * FROM AirDemoSmallTest",
    connectionString = sqlConnString,
    rowsPerRead = 50000,
    colInfo = list(DayOfWeek = list(type = "factor",  levels =
as.character(1:7))))
```

6. 호출 **rxSummary** 쿼리에서 데이터의 요약을 검토 하는 한 번 더 합니다.

R 복사

```
rxSummary(~., data = sqlServerAirDemo)
```

다음 단계

rxDataStep 을 사용하여 청크 분석 수행

이전 단계

rxImport 를 사용하여 메모리에 데이터 로드

RxDataStep (SQL 과 R 심층 분석)를 사용 하 여 청크 분석 수행

이 문서는 데이터 과학 심층 분석 자습서를 사용 하는 방법에 대 한 일부 RevoScaleR SQL Server 와 함께 합니다.

이 단원에서는 사용 하 여는 **rxDataStep** 전체 데이터 세트의 메모리에 로드 하고 기존의 오른쪽에서와 같이 한 번에 처리 될 필요 하지 않고 데이터 청크를 처리 하려면 함수 **rxDataStep** 함수 읽는 데이터 청크를 차례로 데이터의 각 청크를 R 함수를 적용 하 고 다음에 공통 각 청크에 요약 결과 저장 SQL Server 데이터 원본입니다. 모든 데이터를 읽을 때 결과가 결합 됩니다.

팁

이 단원에서는 사용 하 여 대체 테이블을 계산에서 `table` R 에서 함수 이 예제에서는 지침만 제공 하기 위한 것입니다.

실제 데이터 세트를 표로 해야 할 경우 사용 하는 것이 좋습니다는 **rxCrossTabs** 또는 **rxCube** 함수가 **RevoScaleR**,이 대 한 일종의 최적화 작업입니다.

값으로 데이터 분할

1. R 을 호출 하는 사용자 지정 R 함수를 만들 `table` 데이터의 각 청크에서 작동 하 고 새 함수 이름을 `ProcessChunk` 합니다.

R 복사

```
ProcessChunk <- function( dataList) {

# Convert the input list to a data frame and compute contingency table

chunkTable <- table(as.data.frame(dataList))



# Convert table output to a data frame with a single row

varNames <- names(chunkTable)

varValues <- as.vector(chunkTable)

dim(varValues) <- c(1, length(varNames))

chunkDF <- as.data.frame(varValues)

names(chunkDF) <- varNames



# Return the data frame, which has a single row

return( chunkDF )

}
```

2. 계산 컨텍스트를 서버로 설정합니다.

R 복사

```
rxSetComputeContext( sqlCompute )
```

3. 처리 중인 데이터를 보관할 SQL Server 데이터 원본을 정의 합니다. 먼저 SQL 쿼리를 변수에 할당합니다. 그런 다음에 해당 변수를 사용 하 여는 *sqlQuery* 새의 인수 SQL Server 데이터 원본입니다.

복사

```
```R
```
```

```
dayQuery <-  "SELECT DayOfWeek FROM AirDemoSmallTest"

inDataSource <- RxSqlServerData(sqlQuery = dayQuery,

    connectionString = sqlConnString,

    rowsPerRead = 50000,

    colInfo = list(DayOfWeek = list(type = "factor",

        levels = as.character(1:7))))
```

1. 실행할 수 있습니다 **rxGetVarInfo** 이 데이터 원본에 있습니다. 이 시점에서 단일 열을 포함: *Var 1: DayOfWeek, 유형:을 고려 하 고 사용 가능한 비율 수준이 없습니다.*
2. 이 요인 변수를 원본 데이터에 적용하기 전에 중간 결과를 저장할 별도의 테이블을 만듭니다. 다시 방금는 RxSqlServerData 함수를 사용 하면 makign 같은 이름의 기존 테이블을 삭제 하 시겠습니까 데이터를 정의 합니다.

R 복사

```
iroDataSource = RxSqlServerData(table = "iroResults",
connectionString = sqlConnString)

# Check whether the table already exists.

if (rxSqlServerTableExists(table = "iroResults",  connectionString =
sqlConnString))  { rxSqlServerDropTable( table = "iroResults",
connectionString = sqlConnString) }
```

3. 사용자 정의 함수를 호출 `ProcessChunk` 읽을 때로 사용 하 여 데이터를 변환 하는 *transformFunc* 인수에는 **rxDataStep** 함수입니다.

R 복사

```
rxDataStep( inData = inDataSource, outFile = iroDataSource,
transformFunc = ProcessChunk, overwrite = TRUE)
```

4. 중간 결과를 보려면 `ProcessChunk`, 결과를 할당 **rxImport** 변수에 한 다음 콘솔에 결과 출력 합니다.

R 복사

```
iroResults <- rxImport(iroDataSource)
iroResults
```

일부 결과

```
   1    2    3    4    5    6    7
1 8228 8924 6916 6932 6944 5602 6454
2 8321 5351 7329 7411 7409 6487 7692
```

1. 모든 청크의 최종 결과를 계산하려면 열의 합계를 구한 다음 결과를 콘솔에 표시합니다.

R 복사

```
finalResults <- colSums(iroResults)
finalResults
```

결과

```
   1     2     3     4     5     6     7
97975 77725 78875 81304 82987 86159 94975
```

2. 호출 하는 중간 결과 테이블을 제거 하려면 **rxSqlServerDropTable** 합니다.

R 복사

```
rxSqlServerDropTable( table = "iroResults", connectionString =
sqlConnString)
```

다음 단계

로컬 계산 컨텍스트에서 데이터 분석

이전 단계

rxDataStep 을 사용하여 새 SQL Server 테이블 만들기

로컬 계산 컨텍스트 (SQL 과 R 심층 분석)에서 데이터 분석

이 문서는 데이터 과학 심층 분석 자습서를 사용 하는 방법에 대 한 일부 RevoScaleR SQL Server 와 함께 합니다.
이 섹션에서는 로컬 계산 컨텍스트로 다시 전환 하 고 성능을 최적화 하기 위해 컨텍스트 간에 데이터를 이동 하는 방법을 설명 합니다.
I 수는 있지만 더 빠르게 서버 컨텍스트를 사용 하 여 복잡 한 R 코드를 실행 하려면, 때로는 것이 더 편리의 데이터를 가져오는 SQL Server 로컬 워크스테이션에서 분석 하 고 있습니다.

로컬 요약 만들기

1. 모든 작업을 로컬에서 수행하도록 계산 컨텍스트를 변경합니다.

   R 복사

```
rxSetComputeContext ("local")
```

2. SQL Server 에서 데이터를 추출하는 경우 각 읽기에서 추출되는 행 수를 늘리면 대체로 성능이 향상됩니다. 이렇게 하려면 데이터 원본에 대한 *rowsPerRead* 매개 변수의 값을 늘립니다. 이전에는 *rowsPerRead* 값이 5000 으로 설정되었습니다.

   R 복사

```
sqlServerDS1 <- RxSqlServerData(

   connectionString = sqlConnString,

   table = sqlFraudTable,

   colInfo = ccColInfo,

   rowsPerRead = 10000)
```

3. 호출 **rxSummary** 새 데이터 원본에 있습니다.

R 복사

```
rxSummary(formula = ~gender + balance + numTrans + numIntlTrans +
creditLine, data = sqlServerDS1)
```

실제 결과는 **컴퓨터의 컨텍스트에서** rxSummary SQL Server 를 실행할 때와 같아야 합니다. 그러나 작업은 더 빠르거나 느릴 수 있습니다. 데이터가 분석을 위해 로컬 컴퓨터로 전송되므로 이러한 작업 속도는 데이터베이스에 대한 연결에 크게 좌우됩니다.

다음 단계

SQL Server 및 XDF 파일 간에 데이터를 이동

이전 단계

rxDataStep 을 사용하여 청크 분석 수행

SQL Server 및 XDF 파일 (SQL 과 R 심층 분석) 간 데이터 이동

이 문서는 데이터 과학 심층 분석 자습서를 사용 하는 방법에 대 한 일부 RevoScaleR SQL Server 와 함께 합니다.

이 단계에서는 파일을 사용 하는 XDF 원격 및 로컬 컴퓨팅 컨텍스트 간에 데이터를 전송할 방법을 배웁니다. 데이터 파일에에서 저장할 XDF 데이터에서 변환을 수행할 수 있습니다.

파일에 데이터를 사용 하 여 새을 만들고 완료 되 면 SQL Server 테이블입니다. 함수 rxDataStep 고.xdf 파일 및 데이터 프레임 간의 변환을 수행 하는 데이터에 변환을 적용할 수 있습니다.

XDF 파일에서 SQL Server 테이블 만들기

이 연습에서는 신용 카드 사기 데이터 다시 합니다. 이 시나리오에서는 California, Oregon 및 Washington 주의 사용자에 대한 몇 가지 추가 분석을 수행하라는 요청을 받았습니다. 보다 효율적으로 결정 로컬 컴퓨터에만 이러한 상태에 대 한 데이터를 저장 하 고 변수 성별, 카드 소유자, 상태 및 잔액으로 작업 합니다.

1. 다시 사용 된 `stateAbb` 변수를 포함 하 고, 새 변수를 쓸 수준 식별 이전 만든 `statesToKeep` 합니다.

R 복사

```
statesToKeep <- sapply(c("CA", "OR", "WA"), grep, stateAbb)

statesToKeep
```

결과

CA 또는 WA

5 38 48

2. SQL server 에서를 통해 해제 하려는 데이터 정의 사용 하 여는 Transact-SQL 쿼리 합니다. 나중에으로이 변수를 사용 하는 *inData* 에 대 한 인수 **rxImport** 합니다.

R 복사

```
importQuery <- paste("SELECT gender,cardholder,balance,state FROM",
sqlFraudTable,  "WHERE (state = 5 OR state = 38 OR state = 48)")
```

줄 바꿈 또는 탭 등의 숨겨진 문자가 쿼리에 없는지 확인합니다.

3. R 에서 데이터로 작업할 때 사용할 열을 다음으로 정의 예를 들어 더 작은 데이터 세트에 필요한 세 개의 요인 수준, 쿼리만 세 가지 상태에 대 한 데이터를 반환 하기 때문에 합니다. 적용 된 `statesToKeep` 변수를 포함 하도록 올바른 수준 식별 합니다.

R 복사

```
importColInfo <- list(

    gender = list( type = "factor",  levels = c("1", "2"), newLevels
= c("Male", "Female")),

    cardholder = list(  type = "factor",  levels = c("1", "2"),
newLevels = c("Principal", "Secondary")),
```

```
    state = list(   type = "factor",  levels =
as.character(statesToKeep), newLevels = names(statesToKeep))

        )
```

4. 계산 컨텍스트를 설정 **로컬**로컬 컴퓨터에서 사용할 수 있는 모든 데이터를 원하는 때문에 있습니다.

R 복사

```
rxSetComputeContext("local")
```

rxImport 함수 로컬 XDF 파일에 지원 되는 데이터 소스에서 데이터를 가져올 수 있습니다. 하지만 동일한 쿼리를 반복 해 실행 되지 않도록 데이터에 대해 많은 다르게 분석 하려는 경우 데이터의 로컬 복사본을 사용 하는 것이 편리 합니다.

5. 이전에 인수로 정의 된 변수를 전달 하 여 데이터 원본 개체를 만들 **RxSqlServerData** 합니다.

R 복사

```
sqlServerImportDS <- RxSqlServerData(
    connectionString = sqlConnString,
    sqlQuery = importQuery,
    colInfo = importColInfo)
```

6. 호출 **rxImport** 라는 파일에 데이터를 쓸 `ccFraudSub.xdf`, 현재 작업 디렉터리에 있습니다.

R 복사

```
localDS <- rxImport(inData = sqlServerImportDS,
    outFile = "ccFraudSub.xdf",
    overwrite = TRUE)
```

`localDs` 에서 반환 된 개체는 **rxImport** 함수는는 간단한 **RxXdfData** 나타내는 데이터 원본 개체는 `ccFraud.xdf` 데이터 파일을 디스크에 로컬로 저장 합니다.

7. XDF 파일에 대해 rxGetVarInfo 를 호출하여 데이터 스키마가 같은지 확인합니다.

R 복사

```
rxGetVarInfo(data = localDS)
```

결과

rxGetVarInfo(data = localDS)

Var 1: gender, Type: factor, no factor levels available

Var 2: cardholder, Type: factor, no factor levels available

Var 3: balance, Type: integer, Low/High: (0, 22463)

Var 4: state, Type: factor, no factor levels available

8. 이제 SQL Server 의 원본 데이터와 마찬가지로 다양한 R 함수를 호출하여 `localDs` 개체를 분석할 수 있습니다. 예를 들어 성별 요약할 수 있습니다.

R 복사

```
rxSummary(~gender + cardholder + balance + state, data = localDS)
```

이제 계산 컨텍스트 사용 및 다양한 데이터 원본 작업 방법을 익혔으므로 재미있는 작업을 시도해 보겠습니다. 다음 및 최종 단원에서는 원격 서버의 사용자 지정 R 함수를 실행 하는 간단한 시뮬레이션을 만들 수 있습니다.

다음 단계

이전 단계

로컬 계산 컨텍스트에서 데이터 분석

간단한 시뮬레이션 (SQL 과 R 심층 분석) 만들기

이 문서를 사용 하는 방법에는 데이터 과학 심층 분석 자습서의 마지막 단계는 RevoScaleR SQL Server 와 함께 합니다.

지금까지 사용 중인 설계 된 R 기능 간의 데이터 이동에 맞게 SQL Server 로컬 계산 컨텍스트 및 합니다. 그러나 사용자 지정 R 함수를 작성하고 서버 컨텍스트에서 실행하려는 경우를 가정해 보세요.

SQL Server rxExec 함수를 사용하여 컴퓨터 컨텍스트에서 임의 함수를 호출할 수 있습니다. 사용할 수도 있습니다 **rxExec** 코어 단일 서버에서 작업을 명시적으로 배포 합니다.

이 단원에서는 간단한 시뮬레이션을 만들려면 원격 서버를 사용 합니다. 시뮬레이션에는 SQL Server 데이터가 필요하지 않습니다. 예제에서는 사용자 지정 함수를 디자인한 다음 **rxExec** 함수를 사용하여 호출하는 방법만 보여 줍니다.

사용 하 여 보다 복잡 한 예제를 보려면 **rxExec**,이 문서를 참조: foreach 및 rxExec 세분화 정교 하지 않은 병렬 처리

사용자 정의 함수 만들기

일반적인 카지노 게임은 다음과 같은 규칙에 따라 한 쌍의 주사위를 굴리는 동작으로 구성됩니다.

- 처음 굴릴 때 7 또는 11 이 나오면 이깁니다.

- 2, 3 또는 12 가 나오면 집니다.
- 4, 5, 6, 8, 9 또는 10 이 나오면 해당 숫자가 포인트가 되고, 다시 포인트를 얻거나(이기는 경우) 7 이 나올 때까지(지는 경우) 계속해서 주사위를 굴립니다.

R 에서 사용자 지정 함수를 만든 다음 여러 번 실행하면 게임을 쉽게 시뮬레이트할 수 있습니다.

1. 다음 R 코드를 사용하여 사용자 지정 함수를 만듭니다.

R 복사

```
rollDice <- function()
{
    result <- NULL
    point <- NULL
    count <- 1
        while (is.null(result))
        {
            roll <- sum(sample(6, 2, replace=TRUE))

            if (is.null(point))
            { point <- roll }
            if (count == 1 && (roll == 7 || roll == 11))
            {  result <- "Win" }
            else if (count == 1 && (roll == 2 || roll == 3 || roll == 
12))
            { result \<- "Loss" }
            else if (count > 1 && roll == 7 )
```

```
            { result \<- "Loss" }
            else if (count > 1 && point == roll)
            { result <- "Win" }
            else { count <- count + 1 }
        }
        result
}
```

2. 분할의 단일 게임을 시뮬레이트하기 위해 함수를 실행 합니다.

R 복사

```
rollDice()
```

이겼나요, 졌나요?

지금 사용 하는 방법을 살펴보겠습니다 **rxExec** 기능을 여러 번 실행 하려면, 달성의 확률을 확인 하는 데 도움이 되는 시뮬레이션을 만들려고 합니다.

시뮬레이션 만들기

SQL Server 컴퓨터 컨텍스트에서 임의 함수를 실행하려면 **rxExec** 함수를 호출합니다. 하지만 **rxExec** 코어가 여기 서버 컨텍스트에 SQL Server 컴퓨터에 사용자 지정 함수를 실행 또는 노드에 걸쳐 병렬로 함수의 분산된 실행을 지원 합니다.

1. 사용자 지정 함수에 인수로 호출 **rxExec** 시뮬레이션을 수정 하는 다른 매개 변수와 함께 합니다.

R 복사

```
sqlServerExec <- rxExec(rollDice, timesToRun=20, RNGseed="auto")
length(sqlServerExec)
```

- *timesToRun* 인수를 사용하여 함수를 실행해야 하는 횟수를 나타냅니다. 이 경우 주사위를 20 회 굴립니다.
- *RNGseed* 및 *RNGkind* 인수를 사용하여 난수 생성을 제어할 수 있습니다. *RNGseed* 를 **auto** 로 설정하면 병렬 난수 스트림이 각 작업자에 대해 초기화됩니다.

2. **rxExec** 함수는 각 실행에 대한 하나의 요인이 포함된 목록을 만듭니다. 그러나 목록이 완성될 때까지 큰 변화는 없습니다. 모든 반복이 완료되면 `length` 로 시작하는 줄에 값이 반환됩니다.

   그러면 다음 단계로 이동하여 승패 레코드 요약을 가져올 수 있습니다.

3. R 의 `unlist` 함수를 사용하여 반환된 목록을 벡터로 변환하고 `table` 컴퓨터 컨텍스트에서 임의 함수를 호출할 수 있습니다.

   R 복사

```
table(unlist(sqlServerExec))
```

결과가 다음과 같이 표시됩니다.

손실 Win 12 8

결론

이 자습서에서는 다음과 같은 태스크를 익혔습니다.

- 분석에 사용할 SQL Server 데이터 가져오기
- R 에서 데이터 원본 만들기 및 수정
- 워크스테이션과 SQL Server 서버 간에 모델, 데이터 및 그림 전달

데이터 파일은 Revolution analytics 웹 사이트에서 사용할 수 있는 10 백만 관찰의 더 큰 데이터 세트를 사용하여 이러한 기술은 시험 하려는 경우: 데이터 세트의 인덱스

이 연습에서는 더 큰 데이터 파일을 다시 사용 하려면 데이터를 다운로드 하 고 각 데이터 원본 다음과 같이 수정 합니다.

1. 변수 수정 `ccFraudCsv` 및 `ccScoreCsv` 새 데이터 파일을 가리키도록
2. 참조 하는 테이블의 이름을 변경 *sqlFraudTable* 를 `ccFraud10`
3. 참조 하는 테이블의 이름을 변경 *sqlScoreTable* 를 `ccFraudScore10`

추가 예제

계산 컨텍스트 및 RevoScaler 함수를 전달 하 고 데이터 변환의 사용, 마스터 한 했으므로이 자습서를 확인해 보십시오.

컴퓨터 학습 서비스에 대 한 R 자습서

이전 단계

SQL Server 와 XDF 파일 간에 데이터 이동