



HAL
open science

Linkspotter : an R package for correlations analysis and visualization

Alassane Samba

► **To cite this version:**

Alassane Samba. Linkspotter : an R package for correlations analysis and visualization. Sixièmes Rencontres R, Jun 2017, Anglet, France. hal-01836428

HAL Id: hal-01836428

<https://hal.science/hal-01836428v1>

Submitted on 27 Jul 2018

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Linkspotter : outil interactif d'exploration et de visualisation de corrélations

Alassane Samba

Orange Labs

2 avenue Pierre Marzin, 22300 Lannion, France

alassane.samba@orange.com

Mots clefs : Corrélation, Information mutuelle, Graphe dynamique, Visualisation, Interface utilisateur.

L'exploration des relations entre les variables est une étape importante dans le processus d'exploration de données. Il permet au Data scientist de mieux comprendre les phénomènes décrits dans les jeux de données. Cela aide également à éviter le sur-apprentissage et à se prémunir contre le « concept drift » dans la modélisation.

Afin de faciliter l'exploration des données, Linkspotter est un package R offrant plusieurs fonctionnalités permettant d'analyser et de visualiser de manière exhaustive en utilisant un graphe toutes les corrélations bi-variées d'un fichier de données.

Ses fonctionnalités principales sont:

- le calcul de plusieurs matrices de corrélation correspondant à différents coefficients
- le partitionnement des variables par apprentissage non supervisé.

Il offre également une interface utilisateur complète, conviviale et personnalisable permettant de :

- visualiser les corrélations à l'aide d'un graphe (les variables correspondant aux noeuds et les corrélations correspondant aux arcs). C'est une nouvelle approche de visualisation qui est proposée plus conviviale que l'affichage d'une matrice de corrélations coloriée.
- visualiser la distribution de chaque variable grâce à son histogramme ou à son diagramme en barres.
- visualiser un lien entre un couple de variables à l'aide de nuage de points, de boîtes-à-moustaches, etc.

En outre, un nouveau coefficient de corrélation que nous appelons Maximal Normalized Mutual Information (MaxNMI) basé sur une discrétisation supervisée Equal-Freq des variables continues est également introduit par Linkspotter. L'intérêt de ce coefficient est qu'il peut être calculé et comparé quel que soit le type de couple de variables (continue vs catégorielle, continue vs continue, catégorielle vs catégorielle).

Tout en offrant de nouveaux algorithmes et méthodes, Linkspotter utilise et combine harmonieusement des fonctionnalités provenant d'autres packages R, à savoir infotheo, minerva, energy, mclust, shiny, visNetwork et rAmCharts.

Le code [1] et une démonstration [2] de Linkspotter sont disponibles en ligne.

Références

[1] <https://github.com/sambaala/linkspotter>

[2] <http://linkspotter.sigmant.net>