

Matrix Learning for Topographic Neural Maps

by

Banchar ArnonkijpanichDoctor of Natural Science in Computer Science
Clausthal University of Technology, 2010

Angesichts bezogen auf die schiere Größe als auch die Auflösung und Dimensionalität rapide wachsender Mengen elektronischer Daten sind adäquate Techniken zur Dateninspektion und -visualisierung ins Zentrum des Data Minings gerückt. Als Folge dieser Entwicklung wurden vielfältige Schemata zur Datenanalyse und -organisation vorgeschlagen, zwei sehr bekannte etwa selbstorganisierende Karten (SOM) und neuronales Gas (NG). SOM, wie von Kohonen vorgeschlagen, und NG von Martinetz als auch Erweiterungen erlauben, Daten in Form von Topologie-erhaltend angeordneten Prototypen zu repräsentieren. Allerdings basieren die meisten Methoden in diesem Zusammenhang auf der euklidischen Metrik, so dass die daraus resultierenden Cluster essentiell eine sphärische Form aufweisen und schlecht an lokale Korrelationen und Verwerfungen angepaßt werden können. Eine allgemeinere Metrik wurde im Zusammenhang von k-means und fuzzy-k-means vorgeschlagen. Diese Metrik ist durch eine adaptive Matrix induziert, so dass generelle ellipsoide Cluster einfach modelliert werden können. Die entstehenden Algorithmen sind allerdings sehr sensitiv bezogen auf die Prototypeninitialisierung, und Konvergenz gegen lokale Optima kann oft beobachtet werden.

In der vorgelegten Arbeit wird dieser Algorithmus durch eine Kombination mit SOM und NG verbessert, die durch die integrierte Nachbarschaftskooperation die Sensitivität gegen Initialisierung stark vermindern. Dabei basiert der vorgeschlagene Ansatz auf einer kanonischen Erweiterung der üblichen Kostenfunktionen von NG und SOM (in der von Heskes vorgeschlagenen Form) und ist konzeptuell sehr eingängig. In der Arbeit wird eine rigide mathematische Grundlage gelegt. Es werden batch Lernregeln für Prototypen und Matrix direkt aus der Kostenfunktion hergeleitet und Konvergenz des Algorithmus bewiesen. Das Ergebnis lässt es zu, den Algorithmus als implizite lokale Hauptkomponentenanalyse (PCA) zu interpretieren und die lokalen Eigenvektoren der Matrix mit den Hauptkomponentenrichtungen zu identifizieren, die die Hauptachsen der elliptischen Cluster beschreiben. Der vorgeschlagene Ansatz stellt damit auch eine theoretische Fundierung für alternative Vorschläge der Literatur, die SOM oder NG mit PCA-Techniken kombinieren.

Da lokale PCA Vektorquantisierung und PCA kombiniert, kann der Ansatz direkt für Klassifikation und Clustering eingesetzt werden. Dieses wird anhand einiger Benchmark-Szenarien getestet. Bildkompression wird als ein Beispiel eingeführt, um die Möglichkeiten von Clustering und Kodierung basierend auf Transformationen zu untersuchen. Ein weiterer Schwerpunkt der Arbeit liegt in der Möglichkeit, implizite lokale PCA für die Dimensionsreduktion und Dateneinbettung einzusetzen. Dazu wird Matrix-Lernen mit Manifold Charting kombiniert. Die resultierende Technik ergibt eine explizite Einbettungsabbildung und approximative inverse Abbildungen. Populäre Alternativen zur Dimensionsreduktion wie etwa LLE oder Isomap erlauben dieses nicht so einfach. Die Nützlichkeit des entstehenden Verfahrens wird in mehreren Anwendungen zur Datenvisualisierung und Strukturlernen bei Mannigfaltigkeiten demonstriert, eine inverse Abbildung wird explizit in einem Anwendungsbereich der dynamischen Texturgenerierung verwandt.