

NORMALITÉ ASYMPTOTIQUE DES VECTEURS PROPRES
D'UN GRAPHE RÉGULIER ALÉATOIRE
[d'après Ágnes Backhausz et Balázs Szegedy]

par Charles BORDENAVE

INTRODUCTION

Nous présentons ici le résultat principal de Backhausz et Szegedy [5] et nous introduisons les définitions les plus importantes.

Grphe. — Un *graphe* $G = (V, E)$ est la paire formée par un ensemble dénombrable V et un ensemble E formé de parties à deux éléments de V . Les éléments de V et E sont appelés respectivement les *sommets* et les *arêtes* du graphe. Cette définition de graphe correspond aux graphes simples (ni boucles ni arêtes multiples). Le *degré* du sommet $x \in V$ est le nombre d'arêtes $e \in E$ telles que $x \in e$. Pour d entier, un graphe est dit *d-régulier* si tous ses sommets ont degré d .

Soient d, n des entiers positifs. Nous noterons $\mathbb{G}(n, d)$, l'ensemble des graphes $G = (V, E)$ d -réguliers tels que $V = \{1, \dots, n\}$. Si dn est pair et $2 \leq d \leq n - 1$ alors $\mathbb{G}(n, d)$ n'est pas vide. Si dn est impair ou $d \geq n$, $\mathbb{G}(n, d)$ est vide.

Soit $G = (V, E)$ un graphe. Pour k entier, $x, y \in V$, un *chemin de longueur k de x à y* est une suite (x_0, \dots, x_k) telle que $x_0 = x$, $x_k = y$ et pour tout $t = 1, \dots, k$, $\{x_{t-1}, x_t\} \in E$. Le graphe G est *connexe* si pour tous $x, y \in V$ il existe un chemin de x à y . La *distance* entre x et y est la longueur du plus court chemin qui les relie. Un *cycle* est un chemin (x_0, \dots, x_k) tel que $x_0 = x_k$ et les sommets (x_1, \dots, x_k) sont tous distincts. Enfin, un *arbre* est un graphe connexe et sans cycle.

Spectre. — On peut associer plusieurs opérateurs à un graphe $G = (V, E)$. Le plus simple est l'*opérateur d'adjacence*, défini dans $\ell^2(V)$ par, pour tous $f \in \ell^2(V)$ et $x \in V$,

$$Af(x) = \sum_{y:\{x,y\} \in E} f(y),$$

où la somme porte sur les sommets y qui partagent une arête avec x . Si le degré des sommets est uniformément borné, l'opérateur A est un opérateur borné et auto-adjoint.

Si le graphe G est d -régulier, l'opérateur $d^{-1}A$ est le noyau de transition de la marche au hasard sur G . Si G est un graphe d -régulier et V est fini alors le vecteur constant $\mathbf{1} \in \ell^2(V)$ défini pour tout $x \in V$ par $\mathbf{1}(x) = 1$ est un vecteur propre de A associé à la valeur propre d .

Il existe de nombreuses relations entre la géométrie du graphe et les propriétés spectrales de son opérateur d'adjacence. Ces dernières années un effort de recherche tout particulier vise à décrire le spectre lorsque le graphe sous-jacent est aléatoire ou quasi-aléatoire. Pour ne citer que quelques références récentes relatives aux graphes réguliers, des outils de combinatoire [19, 12], de la théorie des matrices aléatoires [17, 16, 7, 6, 22], de l'analyse semi-classique [14, 3, 2] ont été utilisés dans ce contexte. Nous allons présenter ici une méthode très originale d'analyse du spectre développée dans [5]. Elle repose sur des liens fructueux entre la théorie de l'information et la convergence locale des graphes (sur les liens entre convergence locale des graphes et spectre, voir [11]). Le résultat principal de Backhausz et Szegedy portera sur les vecteurs propres de A orthogonaux à $\mathbf{1}$ lorsque G est distribué suivant la mesure uniforme sur $\mathbb{G}(n, d)$. Dans la suite de cette introduction, nous allons d'abord énoncer ce résultat sous sa forme la plus simple pour ensuite donner l'énoncé général qui exige une certaine préparation.

Soit $A \in M_n(\mathbb{R})$ une matrice symétrique de taille n . Pour tous $\delta \in [0, 1[$ et $\lambda \in \mathbb{R}$, un *quasi-vecteur propre de déviation δ et de valeur propre λ* est un vecteur non nul $f \in \mathbb{R}^n$ tel que $\|Af - \lambda f\|_2 \leq \delta \|f\|_2$ où $\|\cdot\|_2$ est la norme euclidienne. Un *quasi-vecteur propre de déviation δ* est un quasi-vecteur propre de déviation δ et de valeur propre λ pour un certain $\lambda \in \mathbb{R}$. Évidemment, un vecteur propre est un quasi-vecteur propre de déviation nulle.

Distribution d'un vecteur. — À tout vecteur $f \in \mathbb{R}^n$, la *mesure empirique de ses entrées* est la mesure de probabilité $\text{distr}(f)$ sur \mathbb{R} :

$$\text{distr}(f) = \frac{1}{n} \sum_{x=1}^n \delta_{f(x)},$$

où δ est la distribution de Dirac. En termes probabilistes, $\text{distr}(f)$ est la loi de $f(o)$ où o est uniformément distribué sur $\{1, \dots, n\}$. La loi $\text{distr}(f)$ est donc la *loi d'une entrée typique*. Le second moment de $\text{distr}(f)$ est égal à $\|f\|_2^2/n$ de telle sorte que si f est non nul, $\text{distr}(\sqrt{n}f/\|f\|_2)$ a un second moment égal à 1.

Gaussianité d'un vecteur. — Pour tout $\sigma \in \mathbb{R}_+$, on note traditionnellement $N(0, \sigma^2)$ la mesure de probabilité gaussienne sur \mathbb{R} centrée et de variance σ^2 . Pour $\sigma = 0$, on

pose $N(0, 0) = \delta_0$. La *proximité d'un vecteur* $f \in \mathbb{R}^n$ non nul à un vecteur gaussien centré est définie comme

$$D(f) = \inf_{\sigma \in [0, 1]} d_L(\text{distr}(\sqrt{n}f/\|f\|_2), N(0, \sigma^2)),$$

où d_L est la *distance de Lévy-Prohorov* (toute autre distance qui définit la topologie faible conviendrait également). Rappelons que si μ et ν sont deux mesures de probabilités sur un espace métrique (M, d) alors, en notant $B(M)$ sa tribu borélienne, on a

$$d_L(\mu, \nu) = \inf \{ \varepsilon > 0 : \forall A \in B(M), \mu(A) \leq \nu(A^\varepsilon) + \varepsilon \text{ and } \nu(A) \leq \mu(A^\varepsilon) + \varepsilon \},$$

où pour tous $A \in B(M)$ et $\varepsilon > 0$, on note A^ε l'ensemble des éléments de M à distance au plus ε de A .

Considérons deux cas extrêmes de vecteurs $f \in \mathbb{R}^n$ « proches » d'un vecteur gaussien au sens que $D(f)$ est petit. Si f est un vecteur de la base canonique alors $\text{distr}(\sqrt{n}f) = 1/n \cdot \delta_{\sqrt{n}} + (1 - 1/n) \cdot \delta_0$. Il est donc immédiat que lorsque n tend vers l'infini, $\text{distr}(\sqrt{n}f)$ converge faiblement vers $\delta_0 = N(0, 0)$. Si f est un vecteur aléatoire gaussien standard dans \mathbb{R}^n (les coordonnées de f dans une base orthogonale sont des variables gaussiennes $N(0, 1)$ indépendantes) alors la loi faible des grands nombres implique que lorsque n tend vers l'infini, la variable aléatoire $d_L(\text{distr}(f), N(0, 1))$ converge en probabilité vers 0 et $\|f\|_2/\sqrt{n}$ vers 1. Dans ces deux cas, $D(f)$ tend vers 0 mais pour des raisons différentes. Dans le premier cas, la norme ℓ^2 du vecteur f est localisée sur $o(n)$ coordonnées (ici une seule). Cela se traduit par une perte de masse ℓ^2 dans le sens que $\text{distr}(\sqrt{n}f/\|f\|_2)$, dont le second moment est égal à 1, converge faiblement vers δ_0 , dont le second moment est nul. Dans le second cas, en probabilité, il n'y a pas de perte de masse et la mesure empirique $\text{distr}(\sqrt{n}f/\|f\|_2)$ converge vers la loi d'une coordonnée de f .

Plus généralement, le lemme élémentaire suivant décrit la proximité à un vecteur gaussien en terme d'une partie localisée et d'une partie proprement asymptotiquement gaussienne.

LEMME 0.1. — Soit $\varepsilon > 0$. Il existe $\delta > 0$ tel que pour tout entier $n \geq 1$ si $f \in \mathbb{R}^n$ vérifie $\|f\|_2 = \sqrt{n}$ et $d_L(\text{distr}(f), N(0, \sigma^2)) \leq \delta$ pour un certain $\sigma \in [0, 1]$ alors il existe $\tau \in [0, 1]$, $a, b \in \mathbb{R}^n$ tels que f se décompose de la façon suivante

$$f = \tau a + \sqrt{1 - \tau^2} b,$$

avec $\langle a, b \rangle = 0$, $\|a\|_2 = \|b\|_2 = \sqrt{n}$, $|\sigma - \tau| \leq \varepsilon$, $d_L(\text{distr}(a), N(0, 1)) \leq \varepsilon$ et $d_L(\text{distr}(b), \delta_0) \leq \varepsilon$.

Théorème principal, forme simplifiée. — La forme simplifiée du théorème principal de [5] est la suivante.

THÉORÈME 0.2. — *Soient un entier $d \geq 3$ et $\varepsilon > 0$. Il existe m et δ strictement positifs tels que, pour tout entier $n \geq m$ avec nd pair, si G est un graphe distribué uniformément sur $\mathbb{G}(n, d)$ et A est sa matrice d'adjacence, alors l'événement suivant a une probabilité au moins $1 - \varepsilon$: tout quasi-vecteur propre f de déviation δ et orthogonal à $\mathbf{1}$ vérifie $D(f) \leq \varepsilon$.*

En regard du lemme 0.1, le théorème 0.2 affirme donc que si f est un vecteur propre de norme 1 de la matrice d'adjacence d'un graphe d -régulier uniforme avec n sommets alors, lorsque n tend l'infini, f se décompose en une partie de masse ℓ^2 concentrée sur $o(n)$ entrées et le reste est asymptotiquement gaussien. Il est conjecturé que la partie localisée de cette décomposition est triviale :

CONJECTURE 0.3. — *Soient un entier $d \geq 3$ et $\varepsilon > 0$. Il existe m positif tel que, pour tout entier $n \geq m$ avec nd pair, si G est un graphe distribué uniformément sur $\mathbb{G}(n, d)$ et A est sa matrice d'adjacence alors l'événement suivant a une probabilité au moins $1 - \varepsilon$: tout vecteur propre f orthogonal à $\mathbf{1}$ vérifie $d_L(\text{distr}(\sqrt{n}f/\|f\|_2), N(0, 1)) \leq \varepsilon$.*

Il est important de remarquer que dans la conjecture ci-dessus, on se restreint aux vecteurs propres. Nous verrons en effet que pour tout $\sigma \in [0, 1]$, il existe une suite de quasi-vecteurs propres f_n de déviation δ_n avec $\delta_n \rightarrow 0$ telle que, en probabilité, $d_L(\text{distr}(\sqrt{n}f_n/\|f_n\|_2), N(0, \sigma^2)) \rightarrow 0$. Voir remarque 2.2.

Nous allons maintenant énoncer le résultat principal de [5]. L'objectif est de mesurer la distance d'un vecteur propre f de la matrice d'adjacence de G uniforme sur $\mathbb{G}(n, d)$ à un processus gaussien qui satisfait, avec probabilité 1, l'équation de vecteur propre sur le revêtement universel de G . Nous allons d'abord expliquer tous ces termes.

Arbre régulier infini. — Pour $d \geq 2$ entier, nous noterons $T_d = (V_d, E_d)$ l'arbre d -régulier infini. Plus précisément, il sera commode d'utiliser la notation généalogique suivante. L'ensemble des sommets de T_d est le sous-ensemble suivant des suites finies d'entiers, \emptyset représentant la suite vide,

$$V_d = \{\emptyset\} \cup \{1, \dots, d\} \cup \bigcup_{k=1}^{\infty} \{1, \dots, d\} \times \{1, \dots, d-1\}^k.$$

On définit le *parent* de $x \in \{1, \dots, d\}$ comme \emptyset . Pour $k \geq 1$ entier, le parent de $x = (x_1, \dots, x_{k+1}) \in \mathbb{N}^{k+1} \cap V_d$ est $(x_1, \dots, x_k) \in \mathbb{N}^k \cap V_d$. Enfin \emptyset n'a pas de parent. L'ensemble des arêtes de T_d est

$$E_d = \{\{x, y\} : x \text{ est parent de } y\}.$$

Nous dirons que y est un *enfant* de x si x est le parent de y . Nous dirons que y est un *descendant* de x si il existe une suite (x_0, \dots, x_k) avec $x_0 = x$, $x_k = y$ et x_{t-1} est le parent de x_t pour tout entier $1 \leq t \leq k$ (en d'autres termes, x est un suffixe de y).

Pour d pair, l'arbre T_d est isomorphe au graphe de Cayley du groupe libre engendré par $d/2$ générateurs libres et leurs inverses. Pour tout d entier, T_d est aussi le graphe de Cayley du groupe librement engendré par d copies de $\mathbb{Z}/2\mathbb{Z}$ et ses générateurs libres.

Revêtement aléatoire. — Soit $G = (V, E)$ un graphe d -régulier. Nous dirons qu'une application $\pi: V_d \rightarrow V$ est un *revêtement de G* si π est un homéomorphisme local au sens où pour tout $x \in V_d$, l'image par π des d voisins de x dans T_d sont les d voisins de $\pi(x)$ dans G . Remarquons que $\pi(V_d)$ est alors une composante connexe de G .

Tout graphe d -régulier admet un revêtement. Si V est fini, alors il existe une mesure de probabilité naturelle sur l'ensemble de revêtements de G . Si G est connexe, ce *revêtement aléatoire* π est caractérisé par la propriété que pour tout automorphisme ϕ de T_d , $\pi \circ \phi$ et π ont même loi. Si G n'est pas connexe, pour caractériser de façon unique cette mesure, nous supposons également que $\pi(\emptyset)$ est uniformément distribuée sur V .

Ce revêtement aléatoire peut être construit explicitement de la façon suivante. Soit $(\sigma_x)_{x \in V_d}$ une famille de permutations aléatoires indépendantes, σ_\emptyset permutation uniformément distribuée dans S_d (le groupe symétrique à d éléments) et pour tout $x \in V_d \setminus \{\emptyset\}$, σ_x uniforme dans S_{d-1} . Le revêtement aléatoire est défini itérativement de la façon suivante. Tout d'abord, $\pi(\emptyset)$ est distribué uniformément sur V et pour tout $i \in \{1, \dots, d\}$, $\pi(i) = v_{\sigma_\emptyset(i)}$ où $\{v_1, \dots, v_d\}$ sont les voisins de $\pi(\emptyset)$ dans G . Ensuite, par récurrence sur $k \geq 1$, pour tout $x \in \mathbb{N}^k \cap V_d$, on étend π en posant pour tout $i \in \{1, \dots, d-1\}$, $\pi((x, i)) = v_{\sigma_x(i)}$ où $\{v_1, \dots, v_{d-1}\}$ sont les $d-1$ voisins de $\pi(x)$ différents de $\pi(y)$, y étant le parent de x .

Distribution d'un vecteur sur le graphe. — La preuve du théorème 0.2 repose sur la possibilité d'associer à la paire formée par un graphe d -régulier $G = (V, E)$ et un vecteur $f \in \mathbb{R}^V$ un processus aléatoire sur T_d qui est invariant par les automorphismes de l'arbre. Cette idée à la fois simple et profonde remonte au moins à Benjamini et Schramm [9]. Plus précisément, soit $G = (V, E) \in \mathbb{G}(n, d)$ un graphe d -régulier avec sommets $V = \{1, \dots, n\}$. On peut définir la *loi d'un vecteur vue d'un sommet typique du graphe* de la façon suivante. Soient M un espace métrique et $f \in M^V$. On munit M^{V_d} d'une distance qui induit la topologie produit. On définit $\text{distr}_G(f)$ comme la mesure de probabilité sur M^{V_d}

$$\text{distr}_G(f) = \text{loi de } f \circ \pi,$$

où $\pi: V_d \rightarrow V$ est le revêtement aléatoire de G défini ci-dessus.