

Le pouvoir pathogène chez Ralstonia solanacearum phylotype II génomique intégrative et paysages transcriptomiques en relation avec l'adaptation à l'hôte

Florent Ailloud

► To cite this version:

Florent Ailloud. Le pouvoir pathogène chez Ralstonia solanacearum phylotype II génomique intégrative et paysages transcriptomiques en relation avec l'adaptation à l'hôte. Biologie moléculaire. Université de la Réunion, 2015. Français. NNT: 2015LARE0009. tel-01211458

HAL Id: tel-01211458 https://theses.hal.science/tel-01211458

Submitted on 5 Oct 2015

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. UNIVERSITÉ DE LA RÉUNION Faculté des Sciences et Technologies Ecole doctorale Sciences Technologies et Santé

THÈSE Pour obtenir le diplôme de DOCTORAT

Discipline : Microbiologie, spécialité phytopathologie UMR Peuplements Végétaux et Bioagresseurs en milieu Tropical

Le pouvoir pathogène chez *Ralstonia solanacearum* phylotype II : génomique intégrative et paysages transcriptomiques en relation avec l'adaptation à l'hôte.

par

Florent AILLOUD

Soutenue le 3 avril 2015 devant le jury composé de :

Stéphane POUSSIER, Professeur, Université de la Réunion	Président
Sylvain BRISSE, Directeur de recherche, Institut Pasteur	Rapporteur
Stéphane GENIN, Directeur de recherche, CNRS	Rapporteur
Charles MANCEAU, Directeur de la Santé des Végétaux, ANSES	Examinateur
Valérie VERDIER, Directrice de recherche, IRD	Examinatrice
Philippe PRIOR, Directeur de recherche, INRA	Directeur de thèse

Titre : Le pouvoir pathogène chez *Ralstonia solanacearum* phylotype II : génomique intégrative et paysages transcriptomiques en relation avec l'adaptation à l'hôte.

Ralstonia solanacearum est une bactérie phytopathogène à la gamme d'hôte exceptionnellement large et à la répartition mondiale. Cet organisme présente une biologie à facettes multiples et s'est adapté à quasiment tous les types de sols, à la vie planctonique, et à de nombreux hôtes et plantes réservoirs. Cette capacité d'adaptation est attestée par une très forte hétérogénéité des souches qui unifient ce complexe d'espèces, aussi bien au plan de la diversité génétique, phénotypique, que de la gamme d'hôte. Des approches phylogénétiques ont montré une structuration de la population mondiale en quatre phylotypes qui correspondent globalement à l'origine géographique des souches. Les travaux de thèse portent sur des souches du phylotype II qui ont valeur de modèle expérimental car épidémiologiquement inféodées à un hôte particulier : souches **Moko** pathogènes du bananier, souches **'Brown rot**' adaptées à la pomme de terre et souches émergentes **NPB**, un variant du pouvoir pathogène. La question de recherche centrale porte sur la compréhension des mécanismes d'adaptation à l'hôte. Pour cela, une dizaine de génomes ont été séquencés dans une perspective (i) de revisiter la taxonomie de ce complexe d'espèce, (ii) d'en faire une analyse génomique comparative et (iii) d'analyser les paysages transcriptomiques produits lors de l'infection (in planta). L'ensemble des ces approches complémentaires permettent ainsi d'intégrer la complexité génétique et phénotypique de l'organisme de manière plus **systémique**.

Title : Pathogenicity of *Ralstonia solanacearum* phylotype II : integrative genomics and transcriptomic landscapes associated with host specificity.

Ralstonia solanacearum is a plant pathogenic bacterium globally distributed with a particularly broad host range. This organism is biologically diverse and is adapted to all types of soil, to planktonic lifestyle and to many plant hosts and natural reservoirs. This bacterium is a species complex and its genetic, phenotypic and host range diversity is a direct consequence of adaptation mechanisms. Phylogenetic analyses have divided this species complex into four distinct phylotypes correlating mostly with strains' geographical origin. This thesis focuses on using phylotype II strains as an experimental model due to their adaptation to specific hosts: **Moko** strains pathogenic to banana, '**Brown rot**' strains adapted to potatoes and emergent pathological variant **NPB** strains. Our main research topic is the understanding of **host adaptation processes**. In order to tackle this problematic we sequenced about ten genomes as a starting point of (i) a taxonomic revision of the species complex (ii) a comparative genomic analysis and (iii) an *in planta* transcriptomic analysis. Together, these complementary approaches allow a more **systemic** view of this organism's genetic and phenotypic complexity.

Remerciements

Je souhaite en premier lieu dédier ce manuscrit à mes parents, qui m'ont encouragé à poursuivre cette thèse, puis m'ont soutenu tout du long.

Ces travaux sont le résultat de plus de 3 années effectuées au Cirad (Pôle de Protection des Plantes) à la Réunion, entrecoupées de séjours au département de pathologies des plantes à l'Université du Wisconsin-Madison. A ce titre, je suis reconnaissant envers Philippe Prior, mon directeur de thèse, pour m'avoir procuré tant d'opportunités et de libertés dans la conduite de mes thématiques de recherche; et Caitilyn Allen pour m'avoir accueilli dans son laboratoire et ainsi permis de poursuivre mes hypothèses. Je remercie également Gilles Cellier, mon encadrant du côté de l'Anses, compagnon de bureau et guide gastronomique.

Je remercie les membres de mon comité de thèse, Stéphane Poussier, Isabelle Robène, Bruno Hostachy, Frank Bertolla et Claudine Médigue pour leur soutien et leurs conseils avisés, ainsi que les membres de mon jury Sylvain Brisse, Stéphane Genin, Charles Manceau et Valérie Verdier pour avoir accepté des juger mes travaux.

Je tiens aussi à remercier nos collaborateurs du Genoscope : David Roche, David Vallenet et Valérie Barbe.

Du coté du 3P, merci à Jean-Jacques Cheron, Sylvain Lebon et Jean Michel Baptiste pour leur aide durant les nombreux essais en chambres climatiques. Je remercie également Pierre Lefeuvre pour son introduction sur R et Python. Du coté de Madison, merci aussi aux thésard(e)s d'UW Jonathan Jacobs, Tiffany Lowe, Beth Dalsing, Tuan Minh Tran et Alejandra Huerta pour leur soutien, leurs conseils et leurs projets de collaborations ; et à tous mes colocataires d'ICH et particulièrement Kyle, Leif, Luke et Lucy pour m'avoir fait découvrir les multiples facettes du Wisconsin.

Sommaire

INT	ROD	UCTION	1
		Contexte Questions de recherche	1 4
CH	APIT	RE 1 – SYNTHESE BIBLIOGRAPHIQUE	7
<u>1.</u>	<u>R</u> A	LSTONIA SOLANACEARUM, UNE ESPECE COMPLEXE	7
	А. В. С.	Generalites Taxonomie Spectre d'hote, pathotypes et ecotypes.	7 8 11
<u>2.</u>	PA	THOGENESE	15
	А. В.	MECANISMES GENERAUX DU FLETRISSEMENT BACTERIEN TACTISME ET RECONNAISSANCE DE L'HOTE FLAGELLES, PILI ET FIMBRIAE ENZYMES DE DEGRADATION DE LA PAROI CELLULAIRE (CWDE) SYSTEME DE SECRETION TYPE III (T3SS) ET EFFECTEURS DE TYPE III (T3E) EFFLUX VOIES DE REGULATION EXOPOLYSACCHARIDE (EPS) SPECTRE D'HOTE, ADAPTATION ET MECANISMES DE SPECIATION	16 16 17 18 19 19 21 21
<u>3.</u>	GE	NOMIQUE COMPARATIVE	24
	А. В. С.	Le sequençage haut debit Genomique et bioinformatique Genomique et spectre d'hote chez les phytopathogenes	24 29 34
<u>4.</u>	TR		35
	А. В.	Les methodes d'etude de l'expression genique Amplification par PCR Hybridation Sequençage Transcriptomique et spectre d'hote chez les phytopathogenes	35 37 37 39 42
<u>CH</u>	APIT	RE 2 – REVISION TAXONOMIQUE DU COMPLEXE D'ESPECES	44
<u>CH</u>	APIT	RE 3 – GENOMIQUE COMPARATIVE CHEZ LES ECOTYPES DU PHYLOTYPE II	65
<u>CH</u>	APIT	RE 3 – ADDENDUM DEVELOPPEMENT D'UN OUTIL DIAGNOSTIC	82
<u>CH</u>	APIT	RE 4 – TRANSCRIPTOMIQUE IN PLANTA	87
<u>co</u>	NCI	USION GENERALE ET PERSPECTIVES	106
REF	EREI	NCES BIBLIOGRAPHIQUES	118

Liste des figures et tableaux

Figure 1 – Classification par phylotype et diversité de spectre d'hôte	_7
Figure 2 – Correspondance entre les classifications par race, biovar et division.	9
Figure 3 – Arbre phylogénétique réalisé à partir gène de l'endoglucanase (egl)	10
Figure 4 – Arbre phylogénétique du RSSC réalisé à partir d'une puce pangénomique	10
Figure 5 – Pourriture brune chez la pomme de terre provoquée par les souches brown rot IIB-1.	11
Figure 6 – Flétrissement du bananier par les souches Moko.	12
Figure 7 – Symptômes tardifs de l'infection sur Anthurium (cv. Fire) par une souche IIB-4 NPB.	14
Figure 8 – Principales voies de régulations de la virulence chez R. solanacearum.	20
Figure 9 – Caractéristiques des plateformes de séquençage SGS et TGS.	26
Figure 10 – Poster décrivant l'intégralité des librairies disponibles sur plateforme Illumina.	27
Figure 11 – Construction d'un graphe dans le cadre d'une approche de type « OLC ».	30
Figure 12 – Construction d'un graphe dans le cadre d'une approche de type « K-mer »	31
Figure 13 – Propriétés des méthodes de prédictions d'orthologues les plus répandues	33
Figure 14 – Principe d'une puce à ADN basée sur des ADNc	38
Figure 15 – Diversité nucléotidique des informations obtenues par séquençage dans le cadre d'analyse	es
transcriptionnelles	39
Figure 16 – Principe du SAGE	40
Figure 17 – Evolution des méthodes de classification taxonomique au cours du temps.	44
Figure 18 – Méthodologie utilisée pour produire un arbre à partir de données protéomiques	45
Figure 19 – Matrices de distances génomiques produites avec les algorithmes ANI, MUMi et GGDC	63
Figure 20 – Matrice de présence/absence des facteurs de virulence au sein du RSSC réalisée à partir de	es
génomes séquencés	65
Figure 21 – Phénotypage (inoculation par le pseudotronc) des mutants de délétion du T3E RipAA	79
Figure 22 – Exemple d'un polymorphisme associé à la variation du spectre d'hôte (HAP) chez le gène	
d'un effecteur de type III (ripAN).	80
Figure 23 – La technologie ArrayTube (Alere Technologies)	82
Figure 24 – Puces sur lame de verre	84
Figure 25 – Concept du projet transcriptomique	88
Figure 26 – Concept du Minimal Wilt Gene Set1	15

 Table 1 – Liste d'effecteurs dont le rôle in planta est caractérisé.
 22

Liste des figures associées aux publications :

Chapitre 2

Figure 1 - Denitrification in RSSC	51
Figure 2 - Phylogenetic network derived from the distance matrices generated using all three	methods and
the SplitsTree4 software	54
Figure 3 - Majority-rule consensus tree based on the presence/absence of a consensus MAL	DI-TOF peak
list obtained using MrBayes software	55

Chapitre 3

Figure 1 - Phylogenetic tree of the R. solanacearum species complex inferred from whole genome	
comparisons	_ 70
Figure 2 - Host-range of sequenced R. solanacearum strains.	_ 71
Figure 3 - Comparative diagram of the specific gene content in representative groups of RSSC.	_ 71

Chapitre 4

Figure 1 – Differential expression across all tested comparison	_ 94
Figure 2 – Venn diagram of differentially expressed genes in planta compared to rich medium	_ 96

Liste des annexes

Annexe 1 – Hydroxycinnamic acid degradation, a broadly conserved trait, protects Ralstonia solanacearum from chemical plant defenses and contributes to root colonization and virulence. Tiffany M. Lowe, Florent Ailloud, and Caitilyn Allen. MPMI. 2015

Liste des abréviations

ADNc ADN codant ADNr ADN ribosomique **AHL** AcylHomoserine Lactone AnGST Analyzer of Gene and Species Tree **ANI** Average Nucleotidic Identity **ARNm** ARN messagers **BAC** Bacterial Artificial Chromosome **BDB** Blood Disease Bacterium **BLAST** Basic Local Alignment Search Tool BMM Boucher's Minimal Medium **CCD** Charge-Coupled Devices **CDS** CoDing Sequence **CFU** Colony Forming Unit **CGH** Comparative Genome Hybridization **CPG** Casamino acid-Peptone-Glucose **CWDE** Cell Wall Degrading Enzyme **DD** Differential Display **DDH** DNA-DNA Hybridization DGE Differential Gene Expression **DI** Disease Index **EPS** ExoPolySaccharide **EST** Expressed Sequenced Tags FC Fold Change **FISH** Fluorescence In Situ Hybridization **GFP** Green Fluorescent Protein **GGDC** Genome to Genome Distance Calculator HAP Host Associated Polymorphism **HCA** HydroxyCinnamic Acid HDF HrpB Dependent Factor **HGP** Human Genome Project **HGT** Horizontal Gene Transfer **HTH** Helix Turn Helix **INDEL** INsertion DELetion **IVET** In Vivo Expression Technology **Kb** KiloBase MALDI-TOF Matrix-Assisted Laser **Desorption/Ionization Time Of Flight** MATE Multidrug And Toxic compound Extrusion **MDR** MultiDrug Resistant **MLST** Multi Locus Sequence Typing **MPSS** Massively Parallel Signature Sequencing MRCA Most Recent Common Ancestor **MUMi** Maximum Unique Matches index

MWGS Minimal Wilt Gene Set **NGS** Next Generation Sequencing **NO** Nitrous Oxyde NPB Not Pathogenic to Banana NS-SNP Non-Synonymous Polymorphism **OLC** Overlap Layout Consensus **OMA** Orthologous Matrix **PAC** P1 Artificial Chromosome **PCA** Principal Component Analysis **PCR** Polymerase Chain Reaction **PG** PolyGalacturonase **qPCR** quantitative PCR **RFLP** Random Fragment Length Polymorphism **RND** Resistance Nodulation and cell Division **RSSC** Ralstonia solanacearum Species Complex **SAGE** Serial Analysis of Gene Expression **SGS** Second Generation Sequencing **SMS** Single Molecule Sequencing **T1SS** Type One Secretion System **T2SS** Type Two Secretion System **T3E** Type Three Effector **T3SS** Type Three Secretion System **TGS** Third Generation Sequencing WGS Whole Genome Shotgun **YAC** Yeast Artificial Chromosome

Introduction

Contexte

Les cultures maraîchères et fruitières occupent une place importante dans l'agriculture mondiale et certaines représentent des enjeux stratégiques aussi bien pour l'industrie agroalimentaire que pour l'économie de subsistance (tomate, pomme de terre, banane...). Ces cultures sont cependant mises régulièrement en échec par des maladies causées par un vaste panel de microorganismes (bactéries, champignons, oomycètes, virus, phytoplasmes et viroïdes) et d'insectes nuisibles. Historiquement, ces maladies étaient considérées comme endémiques de différentes régions du globe. La globalisation des échanges et les changements climatiques remettent cependant en question le statut épidémiologique de ces agents pathogènes et favorisent notamment leur distribution rapide (émergence ou réémergence) entre zones tropicales et tempérées.

En tant qu'agents phytopathogènes, les bactéries exercent des contraintes considérables aux cultures avec un impact socio-économique majeur (Elphinstone, 2005). Elles sont capables d'infecter diverses parties de la plante comme les racines, la tige les feuilles ou les fruits et provoquent des symptômes variés sous forme de pourriture, chancre, taches, tumeurs ou flétrissement pouvant entrainer la mort de la plante. Comme dans les domaines médicaux et vétérinaires, la lutte contre les bactéries nuisibles est rendue difficile par leur grande diversité et leur capacité d'adaptation aux hôtes ou aux conditions environnementales. Afin de pouvoir comprendre, limiter et prédire les processus d'adaptation, il est donc impératif d'obtenir des connaissances précises sur la relation entre la diversité bactérienne, les compartiments et niches écologiques occupées et pour ce qui va nous concerner dans ces travaux, les hôtes infectés.

Compte tenu de ses caractéristiques biologiques (qui seront évoquées dans la partie bibliographique), le flétrissement bactérien (Hayward, 1991) fournit un ensemble de modèles d'études académiques de choix, que l'on s'oriente vers l'étude

des interactions plantes bactéries sur des petits génomes modèles (Arabette, Medicago) ou sur des modèles à résonnance plus agronomique (Solanées en général). Cet organisme est très étudié dans le monde¹. Pour ce qui nous concerne, les critères retenus pour élever ces pathosystèmes au rang de modèles ont été (i) l'émergence régulière de variant du pouvoir pathogène et (ii) l'existence de souches adaptées soit à des environnements originaux pour une bactériose tropicale (le cas des souches pomme de terre dites « froides »), soit à un hôte particulier comme les souches à l'épidémiologie clairement inféodée aux bananiers (plantain et Cavendish) et ornementales natives (Héliconia). L'ensemble fournissant un faisceau de ressources biologiques originales que nous avons exploité pour aller vers des questions de recherche innovantes sur la spéciation bactérienne, en relation avec la gamme d'hôte.

R. solanacearum est une bactérie phytopathogène rhizosphérique distribuée mondialement et qui infecte les racines et colonise le tissu vasculaire des plantes (xylème). Contrairement à la plupart des pathogènes de végétaux, cette bactérie a comme particularité une gamme d'hôtes exceptionnellement large. Par ailleurs, *R. solanacearum* est une espèce bactérienne très diverse d'un point de vu génétique et phénotypique comme l'atteste sa présence dans des environnements très différents. Cette diversité génétique a été souvent associée à la capacité naturelle de R. solanacearum pour la transformation bactérienne qui permet d'expliquer la structure mosaïque du génome (Boucher et al., 1992). De même, l'architecture du génome en deux réplicons est sans doute à associer à l'évolution rapide de ce génome, chaque réplicon ayant un rôle important dans la gestion des modifications génomiques: flux de gènes, 'hotspots' de recombinaisons (Lefeuvre et al., 2013). Une même souche pourra ainsi infecter plusieurs hôtes différents, tandis qu'une autre présentera un spectre d'hôte plus restreint et ne sera alors capable d'infecter qu'une seule espèce végétale. La forte capacité d'adaptation chez R. solanacearum est attestée par la diversité géographique, génétique et phénotypique des souches

¹ 44 publications concernant *R. solanacearum* par an depuis 1975 (1745 publications dont 29 reviews). Les contributeurs les plus importants sont l'Université du Wisconsin (8%) et Inra (8%) puis l'Université de Géorgie (4%).

(Cellier and Prior, 2010). Assez curieusement, aucune souche de *R. solanacearum* n'a été décrite à ce jour comme étant pathogène de l'ensemble des hôtes, ce qui laisse à penser que les mécanismes d'adaptations (et de « trade-off ») ont exercé leurs contraintes assez tôt dans le passé évolutif de l'organisme.

A plusieurs reprises, des associations entre des phénotypes et génotypes précis ont été démontrées. Quelques hôtes ne sont sensibles qu'à des souches assignées à une poignée de lignées phylogénétique parmi plus d'une centaine de lignées connues. Au contraire, certaines plantes peuvent flétrir en conditions tropicales suite à l'infection par des souches génétiquement très diverses, mais très peu de lignées conservent néanmoins leur pouvoir pathogène en conditions tempérées. Des phénomènes d'émergence de variants pathogènes ont également été observés. Des souches isolées dans une zone géographique restreinte suite à une épidémie présentaient ainsi une gamme d'hôte qui n'avait encore jamais été observée dans la lignée phylogénétique auxquelles elles ont été assignées (Wicker et al., 2005; Wicker et al., 2007). Cette interrelation entre génotype et pathotype peut ainsi être mise à profit comme modèle d'étude des interactions hôte-pathogène et, plus spécifiquement, pour aborder l'adaptation à l'hôte. En effet, la structure phylogénétique de ces populations, qualifiées d'écotypes, permet de supposer qu'elles sont le fruit d'un processus d'adaptation résultant d'une isolation géographique ou de pressions de sélection causées par les hôtes végétaux environnants. Le concept d'écotype n'est pas reconnu officiellement en taxonomie bactérienne (Brenner et al., 2000a) mais il est néanmoins utile pour décrire la diversité écologique au sein d'une espèce bactérienne (Schloter et al., 2000; Cohan, 2001). Un écotype est défini comme une population bactérienne occupant la même niche écologique et dont la diversité génétique est limitée par des pressions de sélection périodique et/ou la dérive génétique (Cohan and Perry, 2007). Un écotype conserve généralement la totalité (ou presque) des caractéristiques phénotypiques et écologiques de l'espèce et exploite une niche écologique peu différente en comparaison de son espèce (Konstantinidis et al., 2006).

En dehors de la sphère académique, décrire et appréhender le fonctionnement du spectre d'hôte a aussi une importance en agronomie. En effet, les épidémies de flétrissement bactérien sont souvent dramatiques aux plans économiques et sociaux. Une meilleure compréhension de l'adaptation à l'hôte permet de développer des outils diagnostics plus efficaces et d'améliorer ainsi le suivi épidémiologique. De la même façon, une meilleure maîtrise de la diversité génotypique et phénotypique autorise une meilleure gestion des schémas de sélection en amélioration variétale pour la résistance à la maladie, fournissant des critères de sélection plus efficaces.

Grâce à la disponibilité accrue des plateformes de séquençage et aux réductions des coûts des méthodes à haut débit, il est aujourd'hui possible d'obtenir rapidement une grande quantité de données génomiques. Le séquençage massif de souches de *R. solanacearum* représente ainsi une opportunité inédite d'identifier de nouveaux mécanismes d'adaptation à l'hôte et de revisiter les schémas précédemment établis.

Questions de recherche

L'axe thématique central de ma thèse concerne les divergences existantes à différents niveaux au sein du complexe d'espèces *R. solanacearum* (RSSC) (Gillings and Fahy, 1994; Genin and Denny, 2012) et la problématique principale consiste à identifier ces divergences, puis à évaluer leur implication dans la variation du pouvoir pathogène et du spectre d'hôte, voire l'émergence de variants du pouvoir pathogène.

D'un point de vu académique, le chapitre bibliographique introduira le contexte scientifique dans lequel la problématique présentée a été initialement abordée et décrira l'état des connaissances chez l'organisme étudié, puis présentera également les méthodologies retenues afin de tenter de répondre aux hypothèses de travail posées. D'un point de vu technique, le développement de la thématique repose essentiellement sur l'analyse de nombreux génomes de *R. solanacearum*, soit séquencés en préambule de ces travaux, soit issus de bases de données publiques.

Plus particulièrement, nous avons concentrés nos questions de recherche en fonction d'un modèle expérimentale constitué des écotypes du phylotype II (Moko, 'Brown rot' et NPB).

En fonction des objectifs que nous nous sommes assignés, l'interprétation et la restitution des données expérimentales progressivement accumulées sont structurées en trois chapitres complémentaires :

 Hypothèse 1 : Les différences génomiques, protéomiques et phénotypiques au sein du RSSC justifient sa réorganisation taxonomique. Ce projet se propose de diviser le complexe d'espèces actuel en trois espèces distinctes à l'aide de (i) distances génomiques obtenues par comparaison de génomes complets; (ii) profils protéomiques obtenus par MALDI-TOF; (iii) traits phénotypiques partiellement déduits de la littérature. L'intérêt de cette nouvelle classification au niveau académique et agronomique est discuté.

PUBLICATION 1: ADDITIONAL EVIDENCE FOR THE DIVISION OF THE PLANT PATHOGEN RALSTONIA SOLANACEARUM INTO THREE SPECIES INFERRED THROUGH GENOMIC AND PROTEOMIC ANALYSES. PRIOR P., AILLOUD F. ET AL. SYSTEMATIC AND APPLIED MICROBIOLOGY. (SUBMITTED)

Hypothèse 2 : La comparaison génomique des écotypes Moko, Brown rot et NPB du phylotype II permet d'identifier des mécanismes associés à la **spécificité d'hôte.** Les génomes de chacun des écotypes ont été comparés pair-RSSC. qu'à l'ensemble du De à-pair ainsi nouveaux core-génome, pan-génome et core-effectome ont été décrits. L'analyse du contenu en gènes, des polymorphismes et des transferts horizontaux ont permis l'identification de plusieurs gènes candidats. Les résultats d'une analyse fonctionnelle préliminaire par mutagenèse de certains gènes candidats sont discutés.

PUBLICATION 2 : COMPARATIVE GENOMIC ANALYSIS OF *RALSTONIA SOLANACEARUM* REVEALS CANDIDATE GENES FOR HOST SPECIFICITY. AILLOUD F. ET AL. *BMC GENOMICS*. (ACCEPTED)

 Hypothèse 3 : La comparaison transcriptomique in vitro et in planta des écotypes Moko et NPB permet d'identifier des profils d'expression soucheou plante-spécifiques associés à la spécificité d'hôte. Les transcriptomes de chaque écotype ont été obtenus par RNAseq en milieu riche, minimum, sur tomate et sur bananier (Moko uniquement) ou melon (NPB uniquement). Plusieurs méthodes de comptage ont permis de déterminer l'expression différentielle entre des paires de conditions pertinentes d'un point de vu biologique. Le génome respectif de chaque souche a été utilisé comme référence afin d'inférer le rôle des gènes différentiellement exprimés dans la spécificité d'hôte.

PUBLICATION 3 : IN PLANTA COMPARATIVE TRANSCRIPTOMICS OF HOST-ADAPTED STRAINS OF RALSTONIA SOLANACEARUM. AILLOUD F. ET AL. (NOT SUBMITTED)

Finalement, les différents résultats obtenus sont regroupés sous la forme d'une conclusion générale et leurs contributions vis-à-vis de la problématique de l'adaptation à l'hôte sont discutées. Les perspectives envisagées concernant la poursuite de ces travaux ainsi que des hypothèses de travail ou des modèles expérimentaux alternatifs sont décrits.

Cette thèse s'intègre dans la thématique « Génomique et épidémiologie des agents pathogènes émergents » de l'UMR PVBMT. L'ensemble de mes travaux a bénéficié du financement du CIRAD, de l'Anses et de l'Université du Wisconsin.

 Hypothèse 3 : La comparaison transcriptomique in vitro et in planta des écotypes Moko et NPB permet d'identifier des profils d'expression soucheou plante-spécifiques associés à la spécificité d'hôte. Les transcriptomes de chaque écotype ont été obtenus par RNAseq en milieu riche, minimum, sur tomate et sur bananier (Moko uniquement) ou melon (NPB uniquement). Plusieurs méthodes de comptage ont permis de déterminer l'expression différentielle entre des paires de conditions pertinentes d'un point de vu biologique. Le génome respectif de chaque souche a été utilisé comme référence afin d'inférer le rôle des gènes différentiellement exprimés dans la spécificité d'hôte.

PUBLICATION 3 : IN PLANTA COMPARATIVE TRANSCRIPTOMICS OF HOST-ADAPTED STRAINS OF RALSTONIA SOLANACEARUM. AILLOUD F. ET AL. (NOT SUBMITTED)

Finalement, les différents résultats obtenus sont regroupés sous la forme d'une conclusion générale et leurs contributions vis-à-vis de la problématique de l'adaptation à l'hôte sont discutées. Les perspectives envisagées concernant la poursuite de ces travaux ainsi que des hypothèses de travail ou des modèles expérimentaux alternatifs sont décrits.

Cette thèse s'intègre dans la thématique « Génomique et épidémiologie des agents pathogènes émergents » de l'UMR PVBMT. L'ensemble de mes travaux a bénéficié du financement du CIRAD, de l'Anses et de l'Université du Wisconsin.

Chapitre 1 – Synthèse bibliographique

1. Ralstonia solanacearum, une espèce complexe

a. Généralités

R. solanacearum est un bacille à Gram négatif, mobile, aérobie strict de la classe des bêta-protéobactéries. Cette bactérie est l'agent du flétrissement bactérien. Elle peut être isolée dans le sol, l'eau et les plantes. *R. solanacearum* est un phytopathogène vasculaire d'origine tellurique et rhizosphérique capable de transformation naturelle. Son génome, d'une taille totale d'environ 5,5 Mb est organisé en deux réplicons : un chromosome (~3,5 Mb) et un mégaplasmide (~2 Mb). R. solanacearum présente une forte diversité génétique associée à une forte diversité phénotypique qui se traduit par un très large spectre d'hôte comprenant environ 250 espèces végétales réparties dans 50 familles botaniques (Hayward, 1991) (Figure 1). Ces caractéristiques en font un modèle intéressant pour la compréhension des mécanismes moléculaires mis en jeux dans l'adaptation à l'hôte et pour l'identification des processus génétiques responsables des évènements de spéciation chez les bactéries. La diversité de cette bactérie est également attestée par la vaste origine géographique des isolats. Bien que principalement isolé dans les régions tropicales et subtropicales, la répartition mondiale de R. solanacearum est en constante évolution, ce qui nécessite un effort permanent dans le développement de méthodes de diagnostic innovantes pour assurer une veille épidémiologique efficace. Les souches responsables de la pourriture brune ('Brown rot') chez la pomme de terre (French et al., 1977; Martin et al., 1982) sont notamment considérées comme agent potentiel de bioterrorisme aux Etats-Unis (Lambert, 2002) et les souches provoquant la maladie de Moko du bananier sont des organismes de quarantaine en Europe². La pomme de terre et le bananier ainsi que d'autres espèces comme la tomate, le tabac ou encore le géranium font partie des hôtes de *R. solanacearum* ayant une importance agronomique et économique

² www.eppo.org/QUARANTINE/listA2.htm



Figure 1 – Classification par phylotype et diversité de spectre d'hôte. L'arbre phylogénétique a été créé en fonction de distances génomiques calculées a partir de génomes complets. La souche type de l'espèce *R. solanacearum* est encadrée. Hôtes illustrés : banane, tomate, pomme de terre, melon, anthurium, tabac, géranium, giroflier.

majeure (Hayward, 1991). En effet les pertes pour l'industrie agroalimentaire dues au flétrissement bactérien chez la pomme de terre sont estimées à près d'un milliard US\$ par an (Grimault et al., 1994b). La plupart des hôtes sensibles sont des espèces vivrières stratégiques en matière de développement durable, ceci à l'échelle locale dans les pays en voie de développement où une seule de ces cultures peut représenter la majorité de la production et l'alimentation de base de la région. C'est le cas de nombreuses brèdes, terme qui regroupe un ensemble très divers de feuilles comestibles de nombreuses plantes (*Solanum nigrum, S. americanum*...) qui sont cuisinées avant d'être consommées, la cuisson inhibant sans doute les toxines de certains de ces végétaux.

L'étude de cet organisme présente donc aussi bien un intérêt dans le champ de la recherche fondamentale, que dans le monde agronomique. *R. solanacearum* est ainsi considéré par la communauté internationale comme la seconde plus importante bactérie phytopathogène (après *Pseudomonas syringae*) (Mansfield et al., 2012).

b. Taxonomie

Le flétrissement bactérien causé par *R. solanacearum* a été décrit pour la première fois par Erwin Fink Smith à la fin du 19ème siècle (Smith, 1896). Originalement dénommé *Bacillus solanacearum*, l'agent du flétrissement bactérien a ensuite été successivement connu sous le nom de *Pseudomonas solanacearum* (Smith, 1896) puis *Burkholderia solanacearum* (Yabuuchi et al., 1992) avant d'être finalement renommé *R. solanacearum* en 1995 après une caractérisation phylogénétique par l'intermédiaire entre autres du séquençage de l'ADNr 16S (Yabuuchi et al., 1995).

La classification intraspécifique de *R. solanacearum* a elle aussi fait débat bien avant que l'espèce ne soit intégrée dans le genre *Ralstonia*. Historiquement, un système de classification à trois races, basé sur le spectre d'hôte, a été utilisé pour décrire la diversité de *R. solanacearum* (Buddenhagen et al., 1962). La race 1 ubiquiste infecte de nombreuses solanées comme la tomate, le tabac ou le poivron, quelques mauvaises herbes (plantes adventices) ainsi que les bananiers ornementaux diploïdes (Musa *Ensete ventricosum*). La race 2, au spectre d'hôte restreint, provoque le flétrissement chez les bananiers triploïdes (*Musa* spp.) et les *Heliconia*. Enfin, la race 3 est adaptée aux températures tempérées et est pathogène de la pomme de terre et de la tomate, mais apparait généralement peu virulente chez les autres solanées. Plus tard, les races 4 et 5 furent décrites comme infectant respectivement le giroflier aux Philippines (Aragaki and Quinon, 1965) et le mûrier en Chine (He et al., 1983).

Indépendamment du système de race, celui du biovar fut développé sur la base de la capacité de la bactérie à métaboliser ou à oxyder divers disaccharides et hexoses alcool (Hayward, 1964). Quatre biovars ont été décrit en premier lieu par Hayward, puis deux nouveaux biovars ont ensuite été rapportés, les biovars 5 (He et al., 1983) et 2T (syn. N2) (Hayward et al., 1992). Aucun lien direct ne peut être réellement établi entre les deux systèmes de classification, suggérant qu'ils ne reflètent pas vraiment l'histoire évolutive de *R. solanacearum* (**Figure 2**).

L'évolution des techniques de typage et la transition des méthodes phénotypiques vers des méthodes génotypiques entrainèrent un remaniement important de la classification chez R. solanacearum. L'analyse de la diversité génétique par le polymorphisme de longueur des fragments de restriction (RFLP) de plusieurs *loci* a ainsi permis de distinguer 40 groupes distincts (Cook et al., 1989; Cook and Sequeira, 1994). Parmi ces groupes deux sous-divisions corrélant avec l'origine géographique des souches peuvent être clairement identifiées : la Division 1 « Asiaticum » regroupe des isolats provenant d'Asie et d'Australie, la Division 2 « Americanum » héberge des souches originaires d'Amérique Centrale et d'Amérique du Sud. En étendant l'analyse à une autre collection de souches, une 3^{ème} Division « Africanum » regroupant uniquement des souches d'origine Africaines fut aussi identifiée (Poussier et al., 2000). Enfin, l'analyse de la séquence de l'ADNr 16S confirmera ces résultats et identifiera une sous-division de la division 2 comprenant des isolats d'Indonésie ainsi que des organismes proches : l'agent de maladie du sang du bananier (BDB) et *Pseudomonas syzygii*, l'agent de la maladie de Sumatra du giroflier (Li et al., 1993; Taghavi et al., 1996). Phylogénétiquement, ces deux espèces



Figure 2 – Correspondance entre les classifications par race, biovar et division. L'arbre phylogénétique a été créé en fonction de distances génomiques calculées a partir de génomes complets.

sont très proches des souches de *R. solanacearum* ce qui justifie l'utilisation du terme de « complexe d'espèces » pour décrire cet organisme (Gillings and Fahy, 1994). Cette relation entre groupe génétique et région d'origine des souches suggère fortement que l'isolement géographique a joué un rôle important dans l'évolution de *R. solanacearum*.

Ce système de division fut uniformisé grâce à une analyse phylogénétique supplémentaire basée sur la région intergénique des ADNr 16S et 23S ainsi que sur les séquences des gènes *hrpB* et *egl* (Fegan and Prior, 2005). Le complexe d'espèce est alors divisé en quatre groupes appelés phylotypes (I, II, III et IV). Les phylotypes correspondant respectivement aux divisions Asiaticum, Americanum, Africanum et Indonésia. Chaque phylotype est également sous-divisé en lignées (les feuilles de l'arbre phylogénétique) dénommées sequevar, en fonction des variations (moins de 1%) de la séquence nucléotidique partielle du gène de l'endoglucanase (*egl*) (**Figure 3**). Sur cette base, deux branches majeures peuvent être distinguées au sein du phylotype II : IIA et IIB. Le phylotype IV regroupe des souches appartenant aux espèces *R. solanacearum*, BDB et *R. syzygii*. Dans un contexte de diagnostic, il est possible de déterminer le phylotype d'une souche à l'aide d'une PCR multiplexe (Fegan and Prior, 2005).

La classification en quatre groupes a été ensuite revisitée par des méthodes de plus en plus moderne utilisant toujours plus d'informations génétiques, notamment un schéma de Typage Moléculaire Multi Locus (MLST) (Castillo and Greenberg, 2007) et une puce à ADN d'Hybridation Génomique Comparative (CGH) (Guidot et al., 2007) développée suite au séquençage d'une souche du phylotype I, GMI1000 (Salanoubat et al., 2002) (**Figure 4**). Finalement, le séquençage d'autres souches dans chaque phylotype mais aussi de souches de BDB et de *R. syzygii* a permis d'établir un schéma global de la variabilité génétique entre les différentes classes du complexe d'espèces (Remenant et al., 2010; Remenant et al., 2011). Les distances génomiques établies entre ces génomes suggèrent alors que les phylotypes I+III, II et IV pourraient former trois espèces à part entière.



Figure 3 – Arbre phylogénétique réalisé à partir gène de l'endoglucanase (egl) (Fegan et Prior 2005).



Figure 4 - Arbre phylogénétique du RSSC réalisé à partir d'une puce pangénomique (Cellier et al. 2012)

La connaissance exhaustive et l'assignation réfléchie des espèces et des sousespèces n'ont pas uniquement un intérêt dans le monde de la taxonomie. La classification du complexe d'espèces chez *R. solanacearum* est particulièrement importante si l'on considère l'incidence pratique et décisive dans des domaines stratégiques clés tels que la sélection variétale en agronomie, la mise au point de méthodes de diagnostic et le maintien en quarantaine en épidémiologie.

c. Spectre d'hôte, pathotypes et écotypes.

La gamme d'hôte a toujours été un des principaux centres d'intérêt dans l'étude de *R. solanacearum* et cette propriété a tout d'abord été utilisée comme un outil de classification avec le système des races. Notons que contrairement à la classification des champignons, la classification en race chez *R. solanacearum* n'a aucune valeur de taxon. Aussi, au fur et à mesure que la connaissance du complexe d'espèce a progressé, il a été démontré que la classification en race était devenue obsolète et surtout, n'était plus un modèle approprié pour décrire l'histoire évolutive du complexe d'espèces *R. solanacearum*. Il a cependant été montré que certaines lignées phylogénétiques (sequevar) pouvaient être associées à des pathotypes distincts (Cellier and Prior, 2010).

De nombreuses lignées chez *R. solanacearum* sont capables d'infecter la pomme de terre et entrainent ce qui est communément appelé la pourriture brune ('Brown rot' des anglo-saxons). En dehors des signes caractéristiques de flétrissement et de jaunissement du feuillage, en cas d'infection, des symptômes peuvent également apparaître sur le tubercule et se présentent sous la forme d'exsudats bactériens caractéristiques et d'une décoloration brune à l'origine du nom de la maladie (**Figure 5**). Ces symptômes peuvent apparaître avant le flétrissement et provoquer l'arrêt de la croissance de la plante. Les tubercules infectés participent ensuite à l'infection de nouveaux hôtes et à la dispersion de la souche à une grande échelle. Parmi les lignées responsables de la pourriture brune, les souches de phylotype IIB-1 (historiquement Race 3 biovar 2) ont la particularité d'être adaptées au froid (<24°C) et donc de produire du flétrissement quand les autres lignées ne sont pas



Figure 5 – Pourriture brune chez la pomme de terre provoquée par les souches brown rot IIB-1. (Source : G. Cellier, P. Champoiseau)

capables de survivre (French, 1986; Cellier and Prior, 2010). Ces conditions sont aussi bien retrouvées en région tempérée en Europe et aux Etats-Unis qu'en région tropicale dans les hauts-plateaux andins et africains (Mahbou Somo Toukam et al., 2009). Cette capacité n'est cependant pas reliée à une adaptation directe au froid dans la mesure où il a été montré que cette tolérance est dépendante de la présence de la bactérie *in planta*. En effet, aucune différence significative au niveau de la survie et de la croissance à différentes températures n'a été observée *in vitro* entre les souches tempérées IIB-1 et les autres souches tropicales (Milling et al., 2009). La résistance au froid de cette lignée serait donc complètement induite par l'interaction entre la bactérie et le tubercule. A basse température, la pomme de terre constitue une niche écologique spécifique de la lignée IIB-1 qui peut alors être considérée comme un écotype de *R. solanacearum*.

Le bananier Cavendish (banane fruit, AAA, AAB) et le plantain (banane à cuire, BBB, ABB) sont également des hôtes qui sont infectés par différentes lignées chez *R. solanacearum* (Figure 6). Cependant, les symptômes et le mode de transmission peuvent varier en fonction de différents paramètres. Les souches capables d'infecter le genre Musa provoquent la maladie de Moko. Cette dernière est la plus connue et la plus dévastatrice des formes de flétrissement bactérien du bananier. Historiquement, la première référence de cette maladie précède la description d'E. F. Smith et eut lieu au milieu du 19^{ème} siècle lors des voyages de Schomburgk en Guyane Britannique (Martyn, 1931). Attribué plus tard, le nom de « Moko » vient d'une espèce de plantain (Bluggoe) particulièrement touchée à Trinidad en 1890 (Kelman, 1953). Initialement deux groupes de souches Moko ont été définis par Sequeira (Buddenhagen, 1961): les souches « B » (pour 'Banana' en Amérique Centrale) qui s'établissent dans les tissus vasculaires et sont directement transmissibles par contact des racines ou avec des outils contaminés lors du bouturage ou de la récolte; les souches «SFR» ('Small, Fluidal, Round') en Amérique du Sud et « A » (pour 'Amazon') qui se transmettent rapidement via insectes par l'intermédiaire des bourgeons avant d'envahir les vaisseaux des plantes infectées. De par leur mode de transmission, le 1^{er} groupe (B) entraine souvent une



Figure 6 – Flétrissement du bananier par les souches Moko. Ici, la souche RUN62 a été inoculée soit par injection dans le pseudo-tronc (I) soit par inondation du substrat (C). (Source : G. Cellier)

décoloration vasculaire, un flétrissement et un jaunissement classique des feuilles tandis que les souches du 2nd groupe (SFR et A), transmises par insectes, tendent à provoquer des symptômes au niveau du fruit.

En plus de la maladie de Moko probablement introduite via des boutures de bananiers infectées, les iles des Philippines sont aussi touchées par la maladie de Bugtok sur plantain. Bien que les symptômes soient proches de ceux provoqués par les souches Moko SFR et A sur bananier, le faciès de la maladie dans cette interaction *R. solanacearum*-plantain a fait croire pendant des années à l'existence d'une autre bactérie phytopathogène. *R. solanacearum* sera formellement reconnue comme agent de la maladie de Bugtok dans les années 90 (Soguilon et al., 1995). Les symptômes consistent en un durcissement et une décoloration du fruit immature ainsi qu'un rougissement limité aux vaisseaux du rachis. La distinction faite entre les faciès de maladie Bugtok et Moko à cette époque a pour origine les différents génotypes de plantains cultivés dans les régions concernées par ces maladies, respectivement BBB (Saba et Cadaba) aux Philippines et ABB (Bluggoe) en Amérique.

La maladie du sang du bananier (BDB pour 'Blood Disease of Banana') est encore une autre manifestation du flétrissement bactérien sévissant uniquement en Indonésie et principalement sur les bananiers de génotype ABB (Pisang Kapok). Elle est décrite par Ernst Gaüman dans les années 20 et reconnue alors comme étant causée par *Pseudomonas celebensis* (Gäumann, 1921, 1923). Elle entraine des symptômes proches de la maladie de Moko sur bananier Cavendish mais a la particularité de provoquer une décoloration rouge foncée du fruit à l'origine de son nom. Le rapprochement entre la maladie du sang et *R. solanacearum* sera fait par Eden-Green dans les années 90 (Eden-Green, 1994). Notons que les souches BDB sont inféodées au bananier et, à ce jour, on ne leur connaît aucun autre hôte sensible ou alternatif.

Les analyses phylogénétiques décrites ultérieurement démontrèrent rapidement que BDB appartient à une division distincte des autres maladies de Moko du bananier, tombant dans le phylotype IV. Il a été aussi montré que les maladies Bugtok et Moko sont provoquées par des souches appartenant à la même lignée phylogénétique désignée aujourd'hui IIB-3. Les lignées IIB-4, IIA-6 et IIA-24 ont également été spécifiquement associées à la maladie de Moko (Fegan, 2005; Fegan and Prior, 2006).

Récemment, des souches initialement assignées à la lignée Moko IIB-4 ont été isolées en Martinique (Wicker et al., 2007; Wicker et al., 2009). Ces souches sont cependant des variants pathogènes qui ne présentent pas de virulence sur bananier et sont ainsi désignées NPB pour «Non Pathogène du Bananier». Ces dernières ont par ailleurs élargi leur gamme d'hôte et sont capables d'infecter des cultures de la famille des *Cucurbitaceae* ou des plantes ornementales (**Figure 7**) pour lesquelles les souches Moko (toutes lignées confondues) ne sont pas pathogènes. De plus, les souches NPB sont très agressives sur la tomate et sont capables d'infecter l'ensemble des principales sources de résistance au flétrissement utilisées par les sélectionneurs au plan international, tels qu'Hawaii 7996 (Lebeau et al., 2011).

La maladie de Sumatra correspond au flétrissement du giroflier par les souches de *R. syzygii*, espèce représentée phylogénétiquement par une lignée unique au sein du phylotype IV (Waller and Sitepu, 1975). Certaines souches de *R. solanacearum* sont capables de coloniser partiellement cet hôte, mais seule *R. syzygii* provoque un flétrissement complet. Cependant, le giroflier ne présente pas les caractéristiques d'un pathosystème expérimentale simple compte tenu de l'accomplissement très lent du cycle infectieux. En effet, les symptômes observables n'apparaissent qu'environ 200 jours après l'infection (Eden-Green and Adhi, 1986). De plus, la transmission naturelle ne se fait pas au niveau des racines mais activement, par l'intermédiaire d'un insecte foreur, *Hindola spp*.

Plusieurs écotypes ont donc été distingués au niveau du complexe d'espèces. En dehors du pouvoir pathogène, pouvant, dans une certaine mesure, être déduit par association phylogénétique, la connaissance de la gamme d'hôte de la plupart des souches isolées est très faible et se limite souvent à la plante sur laquelle la souche a



Figure 7 – Symptômes tardifs de l'infection sur Anthurium (cv. Fire) par une souche IIB-4 NPB. (Source : F. Ailloud)

été isolée. De plus, la différence inévitable entre le processus infectieux naturel et les méthodes d'inoculations expérimentales peuvent conduire à surestimer la gamme d'hôte réelle d'une souche.

2. Pathogénèse

Initialement, l'infection débute au niveau du sol où R. solanacearum est capable de survivre de manière prolongée dans la rhizosphère de nombreuses espèces végétales (hôte et non-hôte). La bactérie colonise activement l'environnement racinaire aux niveaux des extrémités (coiffe racinaire), des zones d'émergences de racines secondaires ou bien des blessures provoquées par des insectes, des nématodes ou l'Homme (Vasse et al., 1995). Après infection de la plante, la colonisation se poursuit par l'invasion des espaces interstitielles du cortex racinaire et du parenchyme vasculaire sous forme de micro colonies. A ce stade, la bactérie peut alors pénétrer dans le cylindre vasculaire notamment grâce à la dégradation des parois cellulaires. *R. solanacearum* se multiplie ensuite exponentiellement au sein des vaisseaux de xylème et migre dans la tige jusqu'à attendre des densités cellulaires de l'ordre de 10¹⁰ CFU/ mg de tissu (Grimault et al., 1994a). Finalement, la réduction de la circulation dans les tissus vasculaires est accentuée par la surproduction d'exopolysaccharides par la bactérie. Le flétrissement bactérien précédant la mort de plante hôte est donc provoqué par le blocage des vaisseaux de xylème empêchant ainsi la libre circulation du flux hydrique. Cette obstruction est le fait de la production massive d'exopolysaccharides bactériens, mais est aussi due à la réponse de la plante sensible à l'infection qui émet dans l'ensemble des vaisseaux du xylème (colonisés ou non) du matériel amorphe de type dépôt de callose (Grimault et al., 1994b). En fonction de l'interaction espèce hôte-souche bactérienne, plusieurs symptômes peuvent se développer avant l'apparition du flétrissement : retard de croissance de la plante, jaunissement des feuilles et/ou de la tige, croissance désordonnée des racines. Bien avant le début de la décomposition de la plante, R. solanacearum est également capable de recoloniser le sol en étant

directement relarguée dans le milieu par les racines et pouvant ainsi infecter les plantes alentours (Kelman and Sequeira, 1965; Swanson et al., 2005).

a. Mécanismes généraux du flétrissement bactérien

La versatilité du pouvoir pathogène chez *R. solanacearum* repose sur une large gamme de facteurs de virulence contrôlés par des voies de régulations en cascade.

Tactisme et reconnaissance de l'hôte

Afin de coloniser une plante hôte, *R. solanacearum* doit dans un premier temps l'identifier. Le chimiotactisme permet à la bactérie de répondre à des signaux chimiques émis par la plante. Il a été montré que la reconnaissance de différentes sources de carbones et d'exsudats racinaires (tomate et riz) varie en fonction des souches suggérant que la gamme de signaux reconnus pourrait être associée au spectre d'hôte et aux voies métaboliques disponibles. Un mutant *cheW* n'est plus capable de chimiotactisme et il présente une virulence moindre par rapport à la souche sauvage, une perte de motilité et une distribution désordonnée le long des racines (Yao and Allen, 2006). Un autre type de tactisme, l'aérotactisme, participe également à la virulence. Ce mécanisme consiste en la détection des niveaux d'oxygène dans l'environnement, afin d'optimiser la chaine respiratoire. Un mutant *aer2* présente ainsi une déficience dans les étapes précoces de l'infection.

Flagelles, pili et fimbriae

R. solanacearum possède plusieurs types d'appendices de surface pour accomplir des tâches spécifiques à différentes étapes du cycle infectieux. La mobilité à l'extérieur de la plante, aussi appelée 'swimming motility', est assurée par un flagelle polaire (*flg*) dont la synthèse est assurée par le régulateur *flhDC*. Ce flagelle permet notamment à la bactérie de se diriger vers les racines après détection d'exsudats. Une fois dans la plante, la bactérie devient principalement non-motile. Un mutant non-motile n'est plus capable d'infecter une plante dans des conditions naturelles mais le phénotype virulent est entièrement restauré si la bactérie est directement

injectée dans le xylème suggérant que la motilité flagellaire est uniquement nécessaire dans les étapes précoces de l'infection (Tans-Kersten et al., 2001). La régulation négative de la motilité par l'intermédiaire de *flhDC* est en partie assurée par *motN*. Un mutant *motN* est hypermotile et hyperflagellé mais produit des biofilms plus fragiles (Meng et al., 2011). Ce mutant est également moins virulent, illustrant ainsi l'importance d'une régulation fine de la motilité chez *R. solanacearum*.

Ralstonia est également capable de mobilité sur une surface solide de type « twitching motility » produit par un pili de type IV composé principalement d'un seul type de piline, PilA. Un mutant *pilA* est avirulent quelle que soit la méthode d'infection et perd aussi sa compétence naturelle (Kang et al., 2002). Ces pilis jouent probablement plusieurs rôles au cours du processus infectieux : adhésion, migration au sein de l'hôte et formation de biofilms.

Enzymes de dégradation de la paroi cellulaire (CWDE)

Chez *R. solanacearum* ainsi que chez la plupart des bactéries à Gram négatif, le système de sécrétion de type II (T2SS) est utilisé pour exporter des protéines dans l'espace extracellulaire. Parmi ces protéines on peut trouver de multiples enzymes hydrolytiques qui pourraient permettre de dégrader les parois cellulaires afin d'obtenir des nutriments, mais aussi de progresser au sein de la plante hôte. Deux enzymes cellulolytiques sont secrétées : une endoglucanase (*egl*) et une exoglucanase (*cbhA*). Quatre enzymes pectinolytiques sont secrétées : une pectine méthylesterase (*pme*) dé-méthyle la pectine afin de faciliter sa dégradation par des polygalacturonases (PG), une endoPG (*pehA*) et deux exoPG (*pehB* et *pehC*). La contribution de ces enzymes à la pathogénèse semble cependant limitée. En effet, un mutant *egl* (Roberts et al., 1988), un triple mutant *pehABC* (Gonzalez and Allen, 2003) ou même un mutant pour les six CWDE (Liu et al., 2005) sont toujours capables d'entrainer du flétrissement bactérien et ne présentent qu'une faible réduction de virulence par rapport à la souche sauvage. Néanmoins, il existe très probablement d'autre exo-protéines secrétées par le T2SS encore non identifiées;

en effet un mutant T2SS est moins virulent que le mutant pour les six CWDE (Liu et al., 2005).

Système de sécrétion type III (T3SS) et effecteurs de type III (T3E)

Le système de sécrétion de type III (T3SS) est une autre structure de surface très répandue chez les bactéries pathogènes des végétaux ou des animaux, et également présente chez *R. solanacearum*, qui permet d'injecter des protéines à l'intérieur des cellules hôtes. Le T3SS est nécessaire pour établir une infection et il est recruté dans la plante ou en milieu pauvre en nutriment (Arlat et al., 1992). Il est aussi responsable de la réponse hypersensible (HR) chez les plantes non hôtes (Boucher et al., 1985). Il est codé par les ilots de gènes hrp ('hypersensitive response and pathogenicity') et hrc ('hrp conserved') comportant au total plus de 20 gènes. Les gènes *hrc* codent principalement pour des protéines conservées de la partie basale du T3SS, tandis que les gènes *hrp* codent pour les protéines plus spécifique du pili constitué principalement par la piline HrpY. L'expression du T3SS ainsi que des T3E est contrôlée par un régulateur de type AraC, HrpB qui est lui-même activé par un système à deux composants, HrpG (Vasse et al., 2000). La régulation du T3SS est cependant complexe et implique vraisemblablement de nombreux facteurs et voies de régulation encore inconnues (Zuluaga et al., 2013). Par exemple, il a été montré qu'une protéine chaperonne HpaP est capable d'activer ou de réprimer la sécrétion de certains effecteurs spécifiques (AvrA et PopP1) et de la piline HrpY (Lohou et al., 2014).

Une des spécificités de *R. solanacearum* est son large répertoire d'effecteurs qui a notamment été décrit grâce au séquençage de la souche GMI1000 (Salanoubat et al., 2002). La recherche du motif de régulation d'HrpB (hrp_{II} box), similaire à la PIPbox présente chez les *Xanthomonas* (Cunnac et al., 2004), des analyses transcriptomiques (Occhialini et al., 2005) ainsi que des expériences de translocation (Cunnac et al., 2004; Tamura et al., 2005; Mukaihara et al., 2010) ont permis l'identification et la validation d'un grand nombre d'effecteurs candidats. 72 effecteurs seraient présents au total chez GMI1000 (Poueymiro and Genin, 2009) et peuvent être aussi bien localisés sur le mégaplasmide que sur le chromosome. Certains sont directement situés à côté du T3SS dont les effecteurs *popA*, *popB* et *popC*.

La plupart des effecteurs sont très peu caractérisés et leur rôle ou leur cible sont majoritairement inconnus. PopP1, PopP2, GALA7, AvrA ainsi que les T3E de la famille AWR ont été associés à des variations de la gamme d'hôte et au pouvoir pathogènes à différents niveaux (Coll and Valls, 2013).

Efflux

Chez de nombreuses bactéries pathogènes et environnementales, la tolérance à des l'intermédiaire de efflux. composés toxiques passe par pompes à Par exemple, les résistances multiples aux antibiotiques chez les agents pathogènes humains sont dues en partie à ce type de transporteur. Chez les plantes, les composés antimicrobiens sont des substances de faible poids moléculaire regroupées sous le nom de phytoalexines et sont synthétisés après exposition à des micro-organismes. Parmi les dizaines d'opérons codant pour des pompes à efflux putatives chez R. solanacearum, deux pompes à efflux ont été identifiées comme étant exprimées chez la plante au cours de l'infection : AcrA de la famille RND (Resistance/Nodulation/cell Division) et DinF de la famille MATE (Multidrug And Toxic compound Extrusion). Ces deux systèmes sont activés par deux régulateurs différents, RpoS et HrpB respectivement, et utilisent deux sources d'énergie distinctes, un gradient d'H⁺ et de Na⁺ respectivement. Les substrats exportés par ces transporteurs et leur rôle précis ne sont pas encore connus, des mutants pour chacune de ces pompes présentent cependant une sensibilité accrue à certaines toxines et leur virulence est atténuée (Brown et al., 2007).

Voies de régulation

La pathogénicité chez *R. solanacearum* est contrôlée de façon distincte aux stades précoces et tardifs de l'infection en fonction de conditions environnementales telles que le contact avec les cellules de l'hôte ou la densité bactérienne.

Au début de l'infection - stade précoce - le contact avec la paroi végétale est détecté par un récepteur membranaire PrhA qui transmet ce signal à une cascade de régulations composée de PrhR, PrhI, PrhJ, HrpG et enfin HrpB. HrpG contrôle deux voies de régulation indépendantes : la 1^{ère} concerne des gènes impliqués dans l'adaptation et la survie au sein de l'hôte tandis que la 2^{nde} module l'expression du T2SS, de PehC, du T3SS (genes *hrp*) via HrpB. Simultanément, HrpB est responsable de la production de l'HDF ('HrpB Dependant Factor'), un autoinducteur homologue de l'AHL (AcylHomoserine Lactone) impliqué dans la perception de la densité cellulaire ('quorum sensing'). Cette molécule pourrait également être impliquée dans la perturbation du quorum sensing d'autres bactéries (Delaspre et al., 2007). Néanmoins, le composé reconnu initialement par PrhA n'est pas encore caractérisé. En parallèle, HrpB est co-régulé par PrhG en réponse à divers signaux métaboliques (Plener et al., 2010). Plusieurs travaux suggèrent également qu'HrpG est également co-régulé par des signaux indépendants du contact avec la plante (Zuluaga et al., 2013).

Durant la colonisation - stade tardif -, le régulateur transcriptionnel central PhcA est responsable entre autres de la production de l'exopolysaccharide, d'enzymes cellulolytiques et pectinolytiques ainsi que de la répression des gènes *hrp*, de PG, de sidérophores et de la motilité par l'intermédiaire de nombreux mécanismes de régulations, notamment les systèmes a deux composants VsrA-VsrD et VsrB-VsrC (**Figure 8**). L'activité de PhcA est auto-induite via un 1er système de quorum sensing qui repose sur l'accumulation de 3-OH PAME (3-hydroxypalmitic acid methyl ester) produit par PhcB au sein du xylème et reconnu par un système a deux composants PhcS-PhcR (Flavier et al., 1997). La répression des gènes *hrp* au stade tardif de l'infection et à haute densité cellulaire est cependant remise en cause par des travaux récents (Jacobs et al., 2012; Monteiro et al., 2012; Zuluaga et al., 2013). A son tour, PhcA est responsable d'un 2nd système de quorum sensing via la production d'AHL qui active d'autres facteurs de virulence sous la dépendance d'un système à deux composants SolI-SolR.
a Positively regulated traits



Figure 8 - Principales voies de régulations de la virulence chez R. solanacearum (Genin et Denny, 2012).

Les facteurs de virulence de *R. solanacearum* sont donc très souvent successivement ou simultanément contrôlés par plusieurs cascades de régulations intégrant a leur tour de nombreux signaux endogènes ou exogènes.

Exopolysaccharide (EPS)

R. solanacearum sécrète principalement un hétéropolysaccharide acide, de haut poids moléculaire et riche en azote composé de trimères de N-acétyle galactosamine, d'acide 2-Nacetyl-2-deoxy-L-galacturonic, et de 2-N-acetyl-4-N-(3-hydroxybutanoyl)-2,4,6 trideoxy-D-glucose, communément appelé EPS I (Orgambide et al., 1991) et dont la synthèse et l'exportation sont assurées par l'opéron *eps* de 18kb (Huang and Schell, 1995). L'EPS I représente 90% des exopolysaccharides produits par *R. solanacearum*; 85% sont secrétés, le reste étant associé à la membrane sous forme de capsule (McGarvey et al., 1999).

Des mutants déficients pour la production d'EPS sont quasiment avirulents mais sont toujours capables de croissance *in* planta (Denny and Baek, 1991; Kao et al., 1992). Il est généralement accepté que l'EPS joue un rôle dans l'occlusion des vaisseaux de xylème durant les stades tardifs de l'infection, et il est aussi suggéré qu'il pourrait servir à protéger la bactérie du système de défense de la plante en masquant les structures de surface qui pourraient être reconnues. Cependant, l'EPS I pourrait lui-même être la source d'une réponse immunitaire de la part de l'hôte, notamment dans le cas de plantes résistantes (Milling et al., 2011).

b. Spectre d'hôte, adaptation et mécanismes de spéciation

De par sa diversité génétique et phénotypique, *R. solanacearum* est souvent considérée comme un modèle pour l'identification et la compréhension des mécanismes d'adaptation à l'hôte.

Jusqu'à présent, un nombre limité de souches a fait l'objet de la majorité des études. La souche GMI1000 du phylotype I est de loin la plus étudiée car son génome a notamment été le premier à être complètement séquencé et manuellement annoté (Salanoubat et al., 2002). La tolérance au froid des souches 'Brown rot' a été étudiée chez la souche UW551, dont le génome est disponible. Enfin, la souche K60^T pathogène de la tomate du phylotype IIA-7 est aussi souvent utilisée comme modèle compte tenu de son statut de souche type pour l'espèce (Remenant et al., 2012).

Certaines espèces végétales sont aussi préférentiellement utilisées pour les analyses *in planta*. *Arabidopsis thaliana* et *Medicago truncatula* sont des modèles très largement utilisés en pathologie végétale. Ces espèces modèles sont facilement et rapidement cultivables et sont adaptées aux études de microscopies. Leurs mécanismes de défense sont fortement caractérisés au niveau moléculaire. Leurs « petits » génomes sont séquencés et la simplicité de leur transformation a permis l'établissement d'une vaste collection de lignées mutantes. La tomate (*Solanum lycopersicum*) est également un hôte très répandu possédant des caractéristiques proches d'*Arabidopsis* et de *Medicago* mais qui a l'avantage d'être une espèce pertinente pour le monde agricole.

Comparé au nombre d'hôtes pouvant être infectés par *R. solanacearum*, seulement une poignée d'hôtes est en réalité étudiée. Jusqu'à présent, les variations du spectre d'hôte ont été très majoritairement associées à des effecteurs de type III (**Tableau 1**). PopP1, un membre de la famille YopJ/AvrRxv, restreint la virulence sur *Pétunia* chez la souche GMI1000 (Lavie et al., 2002). PopP2, également membre de la famille YopJ, est reconnu par la protéine de résistance RSS1-R et provoque une réponse immunitaire chez *A. thaliana* (Deslandes et al., 2003). PopP2 est une cystéine protéase qui interagit avec RSS1-R au sein du noyau et pourrait stabiliser cette protéine en empêchant son ubiquitinylation, évitant ainsi sa dégradation par le protéasome (Bernoux et al., 2008; Tasset et al., 2010). GALA7 permet la virulence sur *M. truncatula* chez GMI1000 (Angot et al., 2006). Les GALA sont une famille de protéines contenant des domaines F-box homologues des plantes qui pourraient également intervenir dans le détournement de la voie ubiquitine/protéasome. AvrA, en association avec PopP1, limitent la virulence de GMI1000 sur plusieurs espèces de tabac, *Nicotina tabacum, benthamiana* et *glutinosa* (Poueymiro et al.,

Protein name	Family	Predicted domains	Role in planta	Hosts tested	Mode of action	References	
AvrA	_	-	Avirulence Promotes growth	Nicotiana spp., Tomato	-	Carney and Denny (1990); Robertson <i>et al.</i> (2004); Turner <i>et al.</i> (2009); Macho <i>et</i> <i>al.</i> (2009)	
AvrPphF	HopF2	-	Promotes growth	Tomato, Eggplant, Bean	-	Macho et al. (2010)	
Awr1	AWR	-	Promotes growth	Tomato, Eggplant	-		
Awr2		-	Avirulence Promotes growth	Nicotiana spp., Tomato, Eggplant, Arabiodpsis	-	Solé et al. (2012)	
Awr4		-	Restricts growth	Arabidopsis	-		
Awr5		-	Avirulence Restricts growth	Nicotiana spp., Tomato, Eggplant, Arabiodpsis	-		
Gala1 Gala3 Gala5 Gala6 Gala7	GALA	LRR repeats, F-box	- - - Host specificity factor	- - - Medicago truncatula	Interaction with SKP1- like proteins	Angot et al. (2006)	
РорА	-	Harpin	-	Nicotiana	Formation of ion-	Racapé et al.	
-	РорС	LRR	Promotes growth	Eggplant, Bean	-	Macho et al. (2010)	
PonP1			Avirulence	Petunia	_	Lavie et al. (2002)	
PopP2	YopJ	Ser/Thr acetyl- transferase, functional NLS	Avirulence Promotes growth	Arabidopsis, Tomato, Eggplant, Bean	Nuclear relocalization of RRS1-R and RD19, binds RRS1-R	Deslandes <i>et al.</i> (2002); Deslandes <i>et al.</i> (2003); Bernoux <i>et al.</i> (2008); Macho <i>et</i> <i>al.</i> (2010)	
Skwp4	SKWP	Heat/armadillo- related repeats	Promotes growth	Eggplant	-		
Rip19	AvrBs3	Central repeats	Promotes growth	Eggplant	-		
Rip34	HopD1	-	Promotes growth	Tomato, Eggplant, Bean	-	Macho et al.	
Rip39	HopAV1	Coiled-coil	Promotes growth	Eggplant	-	(2010)	
Rip64	HopR1	-	Promotes growth	Eggplant	-]	
Rip3	-	Ankyrin repeat	Promotes growth	Eggplant	-]	
Rip55	-	-	Promotes growth	Eggplant	-		
Rip23	-	-	Promotes growth	Eggplant	-		

 Table 1 – Liste d'effecteurs dont le rôle in planta est caractérisé (adapte de Coll et Valls, 2013).

2009). Certains membres de la famille AWR, caractérisée par le tripeptide alaninetryptophane-arginine, restreignent la virulence chez *A. thaliana* (Sole et al., 2012).

Une seule protéine n'étant pas un T3E a pour l'instant été associée à la gamme d'hôte. Rsa 1, une aspartate protéase identifiée chez une souche du phylotype IV non pathogène du piment, entraine la perte de la virulence sur piment une fois introduite chez une souche du phylotype I naturellement pathogène du piment (Jeong et al., 2011). Rsa1 est aussi requise pour la virulence sur pomme de terre mais ne confère cependant pas le phénotype sur la souche du phylotype I. Bien que n'étant pas un T3E, Rsa1 est régulée par HrpB via une hrp_{II}box et serait potentiellement secrétée par l'intermédiaire du T2SS.

La résistance au froid des souches responsables de la pourriture brune chez la pomme de terre peut également être considérée comme une forme d'adaptation à l'hôte compte tenu que ce phénotype est directement lié à l'interaction hôte-bactérie (Milling et al., 2009). En effet, *in vitro*, la survie et la croissance des souches R3bv2 n'est pas supérieure à celle des autres *R. solanacearum* à basse température. Les mécanismes moléculaires gouvernant cette adaptation n'ont cependant pas été découverts.

Hormis GALA7, la totalité des gènes identifiés pouvant influencer la gamme d'hôte sont des facteurs d'avirulence. L'adaptation à l'hôte et en particulier l'évolution du spectre d'hôte reste donc une question ouverte. L'ancêtre commun de *R. solanacearum* était potentiellement un organisme polyphagique/ubiquitaire pouvant exister au sein d'une large gamme d'espèces végétales à l'état latent ou pathogène à divers degré. La gamme d'hôte aurait ensuite évolué via une combinaison de gain de facteurs entrainant l'avirulence chez certaines espèces végétales, mais fournissant probablement un avantage compétitif chez d'autres espèces ou conditions environnementales et, dans certains cas, un gain de facteurs de virulence élargissant le spectre d'hôte et entrainant l'émergence de nouveaux pathotypes.

3. Génomique comparative

La génomique est une discipline consistant en l'analyse de la structure et de la fonction des génomes qui a donné naissance à de nombreux champs de recherche, dont la génomique comparative. La génomique comparative consiste à comparer les génomes de différents organismes afin de mieux appréhender leurs fonctions biologiques à travers leurs points communs et leurs différences, et permet aussi d'étudier l'histoire évolutive de ces organismes.

a. Le séquençage haut débit

Le champ de la génomique a vu le jour grâce au développement de méthodes de séquençage de l'ADN et notamment la méthode de terminaison de chaine mise au point par Frederick Sanger en 1977. La fragmentation aléatoire de l'ADN total, le clonage puis le séquençage individuel et aléatoire de chaque clone par la méthode de Sanger permet ainsi le séquençage de génomes entiers ('whole genome shotgun' ou WGS) (Staden, 1979). La qualité du génome peut être décrite par la profondeur de couverture qui se réfère au ratio du nombre total de base séquencées sur la longueur totale du génome. La restriction de la longueur maximale de séquençage/lecture (< 1kb) signifiait cependant que la durée, le coût et le personnel requis étaient proportionnels à la taille du génome et à la couverture souhaitée.

La stratégie 'shotgun' a été adaptée au cours du temps en fonction des avancées technologiques. De nombreuses variantes se basant sur une cartographie préalable du génome ont été créées, entre autres, afin de limiter la composante aléatoire de cette stratégie: l'ADN total est dans un premier temps divisé en fragments de grandes tailles et clonés dans des vecteurs acceptant des inserts de grande taille (YAC, BAC, PAC, cosmid, fosmid) ; ces clones sont organisés hiérarchiquement à l'aide de méthodes de cartographie génétique (carte de restriction, fluorescence *in situ*) puis ensuite re-fragmentés, sous-clonés et finalement séquencés. Ces variantes sont tombées en désuétude dans les années 90 avec l'augmentation des capacités de

calcul des ordinateurs permettant un assemblage rapide des génomes à partir de large quantité de données de séquences aléatoires.

Le séquençage 'paired-end' représenta une évolution majeure dans le domaine du séquençage de génome. Cette méthode consiste à séquencer les extrémités de fragments de tailles prédéfinies (de 2kb jusqu'à plus de 100kb) : deux lectures, ne se chevauchant généralement pas, sont alors obtenues pour chaque clone (« matepair »). La taille des inserts étant contrôlée, la distance séparant chaque paire est connue et facilite alors le processus d'assemblage (Edwards et al., 1991; Roach et al., 1995).

Finalement, la méthode de terminaison de chaine Sanger sera aussi fortement optimisée au cours du temps. La technique originale utilise la radioactivité pour détecter l'ADN et nécessite par conséquent 4 réactions et 4 migrations distinctes pour différentier les 4 nucléotides, l'utilisation de marqueurs fluorescents de couleurs différentes permet d'unifier le processus en une seule réaction puis migration (Smith et al., 1985; Smith et al., 1986; Prober et al., 1987). La migration sur gel est aussi remplacée par une électrophorèse en capillaire ce qui accélère grandement la séparation des fragments marqués (Cohen et al., 1988; Drossman et al., 1990; Luckey et al., 1990). Ces avancements ouvriront la voie au développement du séquençage automatique à haut débit, le premier séquenceur automatique utilisant des terminateurs fluorescents et des capillaires sera commercialisé par Applied Biosystems (Perkin-Elmer) en 1995.

Malgré ces évolutions technologiques majeures, le séquençage du génome humain débuté en 1990 (« Human Genome Project » ou HGP) prendra tout de même 13 années et nécessitera plusieurs milliards de dollars avant d'être complété par des dizaines de laboratoires répartis dans plus d'une dizaine de pays (Collins et al., 2003). L'achèvement du HGP contribua à l'augmentation de la demande en séquençage et au développement de méthodes plus rapides, précises et moins couteuses dites de « nouvelle/seconde génération » (SGS). Associées à la bulle financière du secteur des biotechnologies, plusieurs solutions ont été commercialisées et mises en concurrence, mais partagent cependant une philosophie commune dérivée du concept de Sanger et du WGS. La première plateforme a été déployée en 2005 par 454 Life Sciences/Roche (GS20) suivi notamment par Solexa/Illumina (Genome Analyzer) en 2006, Applied Biosystems en 2007 (SOLiD) et Ion Torrent en 2010 (PGM). Ces technologies reposent toujours sur la fragmentation de l'ADN total mais elles remplacent l'étape de clonage par une amplification par PCR des fragments en un point donné (fixe) à l'aide d'adaptateurs (librairies). La PCR peut être réalisée sur billes (émulsion PCR (Dressman et al., 2003); 454, SOLiD et PGM) ou sur une surface solide (bridge PCR (Adessi et al., 2000) ; Solexa) et a pour but de produire en parallèle des régions de haute densité à partir de chaque fragment (clusters) afin de faciliter la détection de la réaction de séquençage. La méthode utilisée pour déterminer chaque base diffère entre chaque plateforme, mais consiste toujours en des cycles d'incorporation des nucléotides (séquençage par synthèse ou par ligation), de lavage et de détection du signal (**Figure 9**).

Malgré les évolutions technologiques de chaque nouvelle version, les plateformes de 2^{nde} génération ont souvent plusieurs défauts récurrents. L'amplification par PCR peut introduire des erreurs et entrainer des biais de couverture dans des régions répétées ou à taux extrêmes de GC. Les lectures sont en général plus courtes que par séquençage Sanger et ne permettent pas de résoudre efficacement la plupart des régions répétées. Sur les séquenceurs Illumina, cette différence de taille est due à la désynchronisation progressive des cycles entre les fragments au sein d'un même cluster, le nombre de cycle possible avant que ce phénomène n'entraine une baisse trop importante de la qualité du signal détermine ainsi la longueur maximale des lectures La grande quantité de données générée nécessite également des capacités de calculs accrues afin de réaliser un assemblage *de novo*. Par conséquent, les génomes séquencés par ces plateformes sont souvent incomplets ('Draft genome') et ne permettent pas certaines analyses approfondies comme, par exemple, la caractérisation des variations structurelles. Un recours au séquençage Sanger est souvent nécessaire pour parfaire l'assemblage et obtenir un

Platform	Library/ template preparation	NGS chemistry	Read length (bases)	Run time (days)	Gb per run	Machine cost (US\$)	Pros	Cons	Biological applications	Refs
Roche/454's GS FLX Titanium	Frag, MP/ emPCR	PS	330*	0.35	0.45	500,000	Longer reads improve mapping in repetitive regions; fast run times	High reagent cost; high error rates in homo- polymer repeats	Bacterial and insect genome <i>de novo</i> assemblies; medium scale (<3 Mb) exome capture; 16S in metagenomics	D. Muzny, pers. comm.
Illumina/ Solexa's GA _{II}	Frag, MP/ solid-phase	RTs	75 or 100	4 [‡] , 9 ⁵	18‡, 35§	540,000	Currently the most widely used platform in the field	Low multiplexing capability of samples	Variant discovery by whole-genome resequencing or whole-exome capture; gene discovery in metagenomics	D. Muzny, pers. comm.
Life/APG's SOLiD 3	Frag, MP/ emPCR	Cleavable probe SBL	50	7*, 145	30‡, 50§	595,000	Two-base encoding provides inherent error correction	Long run times	Variant discovery by whole-genome resequencing or whole-exome capture; gene discovery in metagenomics	D. Muzny, pers. comm.
Polonator G.007	MP only/ emPCR	Non- cleavable probe SBL	26	55	125	170,000	Least expensive platform; open source to adapt alternative NGS chemistries	Users are required to maintain and quality control reagents; shortest NGS read lengths	Bacterial genome resequencing for variant discovery	J. Edwards, pers. comm.
Helicos BioSciences HeliScope	Frag, MP/ single molecule	RTs	32*	8‡	37*	999,000	Non-bias representation of templates for genome and seq-based applications	High error rates compared with other reversible terminator chemistries	Seq-based methods	91
Pacific Biosciences (target release: 2010)	Frag only/ single molecule	Real-time	964*	N/A	N/A	N/A	Has the greatest potential for reads exceeding 1 kb	Highest error rates compared with other NGS chemistries	Full-length transcriptome sequencing; complements other resequencing efforts in discovering large structural variants and hanlotive blocks	S. Turner, pers. comm.

*Average read-lengths. *Fragment run. ⁶Mate-pair run. Frag, fragment; GA, Genome Analyzer; GS, Genome Sequencer; MP, mate-pair; N/A, not available; NGS, next-generation sequencing; PS, pyrosequencing; RT, reversible terminator; SBL, sequencing by ligation; SOLiD, support oligonucleotide ligation detection.

Figure 9 - Caractéristiques des plateformes de séquençage SGS et TGS (Metzker et al. 2010).

génome complet. Malgré ces limitations, le SGS représente une évolution majeure par rapport au Sanger, un génome humain draft peut être obtenu en une journée pour environ 1000\$ (sous certaines conditions). Débuté en 2008, un consortium visant à séquencer plus de 1000 génomes humains a atteint la 2^{nde} phase de son projet en 2012 avec 1092 génomes disponibles (Abecasis et al., 2010). Cette génération a également participé à l'explosion des « omiques » dû aux champs d'applications possibles en modifiant le protocole de préparation des librairies. En effet, l'expression des gènes, la structure des ARN, la méthylation, la structure de la chromatine, les modifications des histones ou les interactions protéines-ADN peuvent être étudiés grâce aux plateformes de 2^{nde} génération (**Figure 10**).

Déjà commercialisés, les séquenceurs dits de 3^{ème} génération (TGS) se développent rapidement. Cette génération est caractérisée par la capacité de séquencer individuellement chaque molécule d'ADN ('single molecule sequencing' ou SMS) permettant de se passer d'une étape d'amplification. La détection se fait de manière continue éliminant les problèmes de désynchronisation. Deux types de technologies sont actuellement disponibles. Lancé en 2011, le PacBio (Pacific Biosciences) repose toujours sur le séquençage par synthèse et l'incorporation de nucléotides fluorescents détectés par une caméra. La polymérase est fixée au fond d'un puits de 10 nanomètres de diamètre reposant sur une lame de verre. Fixé sur le phosphate, chaque fluorophore est libéré après incorporation du nucléotide, puis diffuse à la surface du puits. Le très faible diamètre du puits empêche le laser de le traverser totalement et permet d'illuminer uniquement les fluorophores présents au niveau de la polymérase. Le temps d'incorporation étant de trois fois l'ordre du temps de diffusion, un nucléotide incorporé peut être différencié d'un nucléotide non incorporé en fonction de l'intensité du signal. Cette technologie est capable de produire des lectures jusqu'à 10kb, mais elle présente cependant un taux d'erreur généralement supérieur et un débit inférieur aux méthodes de 2^{nde} génération. L'observation en temps réel de l'incorporation permet également d'obtenir des informations supplémentaires sur le nucléotide incorporé comme son état de méthylation par exemple.



Figure 10 - Miniature d'un poster décrivant l'intégralité des librairies disponibles sur plateforme Illumina. (Source : www.illumina.com/LibraryPrepMethods)

Disponible de façon limitée, la technologie du Nanopore (Oxford Nanopore Technologies) représente une approche du séquençage radicalement différente. Intégré à une double membrane lipidique synthétique, un pore modifié d'alphahémolysine est couplé à une exonucléase et un senseur à base de cyclodextrine. Un courant est établi à travers la membrane à l'aide d'un gradient ionique. L'exonucléase dégrade l'ADN et chaque nucléotide passant par le nanopore est individuellement détecté par le changement spécifique de la force ionique.

La 3^{ème} génération n'est donc pas encore arrivée à maturité et plusieurs autres alternatives sont envisagées comme la visualisation directe des molécules d'ADN par microscopie électronique. La longueur des lectures, supérieure au SGS et au Sanger, ainsi que le taux d'erreur inhérent au séquençage de molécules individuelles seront aussi des paramètres à prendre en compte dans l'adaptation des modèles mathématiques permettant de traiter ces données. L'évolution des technologies de séquençage doit donc être accompagnée de l'évolution des méthodes bioinformatiques afin d'améliorer la qualité des génomes produits.

b. Génomique et bioinformatique

Contrairement à l'assemblage basé sur un génome de référence, l'assemblage *de novo* n'utilise que les données des lectures pour produire un génome et représente donc un processus complexe (Miller et al., 2010).

L'évolution des algorithmes d'assemblage *de novo* a naturellement suivi celle des techniques de séquençage, mais aussi celle des capacités informatiques. En effet, de la première à la dernière génération de séquenceurs, l'assemblage a toujours reposé sur le même principe de base : combiner des lectures en un minimum de séquences (contigs) en se basant sur les régions chevauchantes, puis organiser ces séquences en super-séquences (scaffolds) à partir des lectures en pair. La taille des lectures, les taux et les types d'erreurs, le débit de données sont autant de paramètres ayant influencés le développement des logiciels d'assemblage. La 2^{nde} génération a entrainé des changements majeurs dans la philosophie de l'assemblage dus a une forte diminution de la taille des lectures associée à une forte augmentation de la quantité de données par rapport au Sanger (El-Metwally et al., 2013).

Les algorithmes utilisés par les assembleurs sont, pour la grande majorité, basés sur la théorie des graphes. Un graphe est un ensemble de nœuds connectés par des liens pouvant être orientés au sein duquel plusieurs liens forment un chemin. L'assemblage consiste en la réduction progressive par concaténation du nombre de nœuds formant un chemin. Trouver le chemin optimal est un problème de type NPdur (i.e. intrinsèquement difficile) qui ne peut pas être résolu de manière efficace et nécessite donc l'utilisation d'algorithmes heuristiques et d'approximations.

Les répétitions représentent un problème redondant dans le processus d'assemblage (Zhi et al., 2006). Si la partie chevauchante de deux lectures appartient à une région répétée, il n'est pas correct d'assembler les lectures car il n'est pas possible de conclure avec certitude que ces lectures proviennent de la même région. L'augmentation de la taille des lectures et de la couverture accroît les chances d'obtenir une lecture couvrant la totalité de la répétition et possédant des séquences uniques à ses extrémités. Les paires de lecture recouvrant la région répétée ou possédant un membre au sein des répétitions sont également utilisées afin de résoudre cette problématique, car elles permettent d'estimer la taille de cette région.

La précision des séquenceurs est également une composante importante et peut varier fortement en fonction des différentes machines (Harismendy et al., 2009). En effet, deux régions génomiques possédant moins de différences que le taux d'erreurs du séquenceur ne peuvent pas être facilement différenciées du point de vu de l'assembleur.

Les approches de types OLC ('Overlap-Layout-Consensus') sont surtout utilisées pour les données de lectures longues et de précisions moyennes (Sanger et 454) (Myers, 1995). Cette méthode organise les données en graphe contenant un nœud pour chaque lecture et un lien pour chaque chevauchement. Ces chevauchements ('Overlap') sont prédéterminés par des alignements pairs-à-pairs nécessitant beaucoup de puissance de calcul. Les lectures sont assemblées en identifiant des chemins dits Hamiltoniens ne passant qu'une seule fois par chaque nœud en passant par un minimum de lien ('Layout'). Enfin les contigs sont formés en combinant les régions chevauchantes de chaque lecture ('Consensus'). La taille des régions chevauchantes joue un rôle important dans l'efficacité de l'algorithme : une faible taille va augmenter le nombre de liens mais augmenter le nombre de faux-positifs, tandis qu'une grande taille va augmenter le nombre d'impasses dans le graphe avec des lectures ne contenant pas de chevauchement (**Figure 11**).

Les approches de type gloutonne ('greedy') ont été principalement utilisées chez les premiers assembleurs de lectures courtes (phrap, TIGR) et consistent à toujours joindre les lectures possédant le plus grand chevauchement (Pop and Salzberg, 2008). Cette approche est donc très locale et ne prend pas en compte les relations entre les lectures en pair, elle peut de ce fait se retrouver bloquée au niveau de maxima locaux et ne pas produire un assemblage optimal.



Figure 11 – Construction d'un graphe dans le cadre d'une approche de type « OLC ». (Metwally et al. 2013).

Les assembleurs basés sur les graphes de De Bruijn ont connu un développement accru avec l'émergence des lectures courtes et très précises (Illumina) mais sont néanmoins fondés sur des principes datant de l'assemblage de lectures Sanger (Idury and Waterman, 1995). Les nœuds correspondent à des K-mer (chaine de K caractères) et les liens indiquent que ces K-mer se chevauchent par K-1 bases. Chaque lecture est représentée par un chemin au sein du graphe, deux lectures chevauchantes ont les extrémités de leur chemin en commun. Les lectures sont ensuite assemblées en identifiant des chemins dits Eulériens, ne passant qu'une seule fois par chaque lien (Pevzner et al., 2001). L'utilisation de K-mer pour identifier les régions chevauchantes entre des lectures a été un moyen universellement adopté par les assembleurs pour réduire la charge de calcul due au traitement de grande quantité de données. Deux lectures partageant un nombre important de K-mer peuvent-être considérées comme chevauchantes. Le K doit cependant être assez grand pour éviter les faux positifs et assez petit pour éviter les faux négatifs. Ce procédé réduit grandement la charge de calcul comparé notamment à des alignements pair-a-pair. Comparé aux assembleurs OLC, cette technique est néanmoins plus sensible aux répétitions et aux erreurs de séquençage, car chaque base erronée peut induire K nœuds artificiels et provoquer la formation de contigs chimériques (Figure 12).

Plusieurs structures peuvent être détectées dans les graphes formés par les assembleurs et correspondent à différents problèmes. Les 'spurs' sont des impasses généralement provoquées par une erreur de séquençage à la fin d'une lecture. Les nœuds contenant la base erronée étant artificiels, ils ont peu de chance d'être reliés à d'autres nœuds. Ces impasses peuvent aussi être dues à une absence totale de couverture dans une région particulière. Les 'bulles' sont formées par des chemins qui divergent puis convergent successivement. Ces dernières sont provoquées par des erreurs de séquençage au milieu des lectures formant un chemin alternatif. Les 'enchevêtrements', deux chemins convergeant puis divergeant ; et les 'cycles', des chemins convergeant sur eux-mêmes sont dus à des séquences répétées.



Figure 12 – Construction d'un graphe dans le cadre d'une approche de type « K-mer ». (Metwally et al. 2013).

Les impasses sont résolues en supprimant les nœuds aboutissant à des chemins trop courts. Les bulles peuvent être résolues en se basant sur la fréquence des K-mer. Un K-mer contenant une ou plusieurs bases erronées devrait logiquement être retrouvé sur un très faible nombre de lectures. Il faut cependant veiller à prendre en compte les régions de basse couverture qui contiennent aussi naturellement des K-mer peu fréquents. Les enchevêtrements sont séparés en deux chemins distincts en réalignant les lectures sur le graphe ('read threading') ou bien en utilisant les informations des lectures en paire ('mate threading').

L'obtention d'un génome correctement assemblé (peu de contigs, contigs de grande taille) nécessite donc de choisir une méthode d'assemblage appropriée à la stratégie de séquençage choisie initialement. Dans le cadre de la génomique comparative et une fois plusieurs génomes obtenus, il est ensuite important d'établir les relations d'orthologies ou d'homologie de chacun des gènes identifiés.

Les relations d'homologie permettent de déterminer quels sont les gènes partagés par chacun des génomes afin de définir par exemple le core-génome, le pan-génome ou encore le génome accessoire. Les relations d'orthologie apportent entre autres des informations quant a la fonction du gène, s'il a été caractérisé chez une autre espèce. De nombreuses bases de données d'orthologues existent aujourd'hui : COG (Tatusov et al., 1997), eggNOG (Jensen et al., 2008), InParanoid (O'Brien et al., 2005), OrthoDB (Kriventseva et al., 2008), OrthoMCL (Li et al., 2003), OMA (Altenhoff et al., 2011). Chacune de ces bases se distingue par les organismes inclus (eucaryotes/procaryotes), le niveau de curation (manuel/automatique) et les méthodologies employées.

Par définition, les orthologues sont des homologues séparés par un évènement de spéciation. Les orthologues sont donc, généralement, plus divergents génétiquement que les homologues. Dans la littérature, les méthodes permettant de déterminer les relations ancestrales entre gènes sont communément désignées comme des méthodes de prédiction des orthologues, mais sont adaptées et couramment utilisées pour la prédiction des homologues. Au plan méthodologique, plusieurs options existent et certaines sont adaptées à des situations particulières (**Figure 13**). Malgré la multiplication des méthodes publiées et des bases de données parfois associées, elles sont alternativement basées sur quelques principes centraux : la similarité des séquences ('graph based'), la phylogenie ('tree based') ou parfois la synténie. Les approches basées sur la phylogénie sont généralement plus adaptées aux familles de gènes complexes incluant des pertes et des duplications, que les approches basées sur la similarité (Trachana et al., 2011).

A partir de génomes assemblés dont les relations d'orthologies sont connues, il est alors possible de réaliser des comparaisons extensives a différents niveaux : gains et pertes de gènes, duplications, polymorphismes, phylogénies, transferts horizontaux, pressions de sélection... Quand la validation de certaines hypothèses nécessite des analyses peu ambiguës à mettre en place et à interpréter ; d'autres requièrent une réflexion minutieuse sur les méthodes à employer afin de garantir qu'elles soient appropriées aux données disponibles et à la réalité biologique. Par exemple, il existe des méthodes de détection des transferts horizontaux basées sur le GC%, la composition en nucléotides, la fréquence d'oligonucléotides, le contexte génomique, les profiles phylogénétiques ou la congruence entre phylogénie du gène et de l'espèce... Un gène effectivement soumis à des transferts horizontaux ne sera pas nécessairement détecté par toutes ces méthodes ; certaines ne peuvent détecter qu'une signature de transfert au sein d'une famille tandis que d'autres sont capables d'inférer le donneur et le receveur.



Figure 13 – Propriétés des méthodes de prédictions d'orthologues les plus répandues (Trachana et al. 2011).

c. Génomique et spectre d'hôte chez les phytopathogènes

La génomique comparative est donc un champ permettant de caractériser des organismes à divers niveaux à l'aide d'un vaste panel de méthodes bioinformatiques, elles-mêmes en constante évolution. Chez les organismes pathogènes en particulier, les phénomènes d'adaptation et les déterminants du spectre d'hôte peuvent être étudiés par la génomique comparative.

La comparaison de deux oomycètes proches, *Phytophthora infestans*, responsable du mildiou de la pomme de terre, et *P. mirabilis* infectant *Mirabilis jalapa*, une plante herbacée, a conduit à l'identification de plusieurs gènes sous sélection positive parmi lesquels un effecteur de type III inhibiteur de protéase et spécifiquement adapté à chaque hôte via une unique substitution d'acide aminé (Dong et al., 2014).

La caractérisation génomique d'une collection de souche de *Xanthomonas axonopodis*, une bactérie pathogène de nombreuses plantes à l'échelle de l'espèce, a décrit une évolution en deux étapes : une 1^{ère} étape de diversification généraliste, et une 2^{nde} étape de formation d'écotypes avec des gammes d'hôtes distinctes. Les traces d'échanges génétiques récents entre écotypes suggèrent qu'ils pourraient favoriser l'émergence de nouveaux pathotypes (Mhedbi-Hajri et al., 2013).

Chez *R. solanacearum*, une dizaine de génomes répartis entre les quatre phylotypes ont été séquencés jusqu'à présent (Genin and Denny, 2012). La confrontation des génomes de deux souches Brown rot (IIB-1) présentant des différences de virulence importantes sur tomate et pomme de terre a mis à jour une délétion de 77kb hébergeant des facteurs contribuant à la pathogénèse (Gonzalez et al., 2011). L'utilisation de puces d'hybridation génomique comparative (CGH) (Guidot et al., 2007) (Cellier et al., 2012) (Lefeuvre et al., 2013) et la comparaison de génomes de chaque phylotype (Remenant et al., 2010) rapportent des différences de dynamiques dans l'évolution du chromosome et du mégaplasmide. En effet les gènes situés sur le mégaplasmide sont peu conservés et possèdent une synténie plus faible que les gènes portés par le chromosome. La taille du mégaplasmide est également

plus variable que celle du chromosome, suggérant qu'il pourrait contenir préférentiellement des facteurs d'adaptation à l'hôte : il est notamment plus petit chez des pathotypes ayant une gamme d'hôte très réduite comme BDB et *R. syzygii* (Remenant et al., 2011).

4. Transcription et transcriptomique

a. Les méthodes d'étude de l'expression génique

La transcriptomique est, par définition, l'étude de toutes les molécules d'ARN produites par une cellule (i.e. le transcriptome). Bien que, théoriquement, la transcriptomique concerne aussi bien les ARN messagers (ARNm) que les ARN ribosomaux, de transfert et les petits ARN, la caractérisation du transcriptome se focalise, en pratique, sur l'expression des gènes et donc des ARNm. Cela s'explique en partie par le fait que l'implication des ARNm dans la biosynthèse des protéines est connue depuis les années 40 tandis que les mécanismes de régulation post-transcriptionnelle via des ARN interférants n'ont été découverts qu'à partir années 90 (Fire et al., 1998).

Historiquement, l'étude de l'expression des gènes se faisait principalement par Northern blot, une technique similaire au Southern blot consistant à extraire les ARN totaux, les séparer par électrophorèse puis détecter directement un transcrit d'intérêt à l'aide d'une sonde marquée après un transfert du gel sur membrane (Alwine et al., 1977). Plus tard, les sondes marquées par fluorescence pourront être directement hybridées sur des cellules ou des tissus perméabilisés et observées par microscopie afin d'étudier notamment la localisation des transcrits (FISH : Fluoresence In Situ Hybridization) (Langer-Safer et al., 1982). Du au caractère transitoire *in vivo* et à l'instabilité *in vitro* (RNAses présentes dans l'environnement) de la molécule d'ARN, la transcriptomique a rapidement évolué grâce au développement de multiples procédés ingénieux permettant de caractériser l'expression de manière indirecte. Globalement, deux types de méthodologie ont été universellement adoptés par la communauté scientifique :

Le premier type de méthodologie repose sur l'observation de l'expression des gènes au sein de la cellule (donc sans risque de dégradation accidentelle des ARN) par l'intermédiaire de gènes dits « rapporteurs » (marqueurs) transcrits par la machinerie cellulaire (IVET : In Vivo Expression Technology) (Mahan et al., 1993; Mahan et al., 2000; Rediers et al., 2005). Les marqueurs et les méthodes de détection associées sont très variés et autorisent une grande diversité de modèles expérimentaux : résistance antibiotique, auxotrophie, fluorescence (GFP), luminescence (luciférase), absorbance (B-galactosidase). Ces techniques ne détectent pas en tant que tels les transcrits, mais dépendent de l'utilisation du promoteur situé en amont du gène d'intérêt. Le gène rapporteur est placé dans un vecteur sans son promoteur d'origine, puis des séquences promotrices d'intérêt ou des morceaux d'ADN aléatoires provenant d'une librairie génomique sont insérés en amont de ce gène. La librairie de vecteurs d'expression ainsi créée est ensuite transfectée dans des cellules sauvages de l'organisme étudié. Enfin, l'expression du marqueur est criblée chez chacun des transformants dans des conditions expérimentales prédéterminées, afin de déterminer si l'insert contient un promoteur actif dans une condition spécifique. Par conséquent, les avantages majeurs de cette méthodologie sont la possibilité d'étudier la transcription, sans connaissance préalable du génome, in vitro ou in vitro, grâce à la diversité des marqueurs utilisables. Par exemple, une bactérie pathogène peut être étudiée dans son hôte naturel en identifiant une auxotrophie la rendant avirulente et un marqueur complémentant cette auxotrophie; les transformants contenant un promoteur actif sont alors les seuls dont la virulence est restaurée. Alternativement et notamment dans le cas de la GFP, le gène marqueur peut être fusionné au gène dont on veut suivre l'expression qui produit alors une protéine de fusion fluorescente ; la transcription est alors détectée via la traduction de cette protéine. Cette méthode requiert cependant une connaissance plus approfondie du génome.

Le second type de méthodologie repose sur la détection des ARNm par amplification, hybridation et/ou séquençage via une conversion initiale en ADN codants (ADNc), plus stables, par rétrotranscription.

Amplification par PCR

La PCR quantitative en temps réel (RT-qPCR) est basée sur l'amplification d'un ADNc à l'aide d'amorces dirigées contre un gène spécifique et couplées ('quenched') à un fluorochrome (Ferre, 1992; Volkenandt et al., 1992). Lors de l'élongation, le fluorochrome est relâché par l'activité exonucléase 5' de la Tag polymérase. En parallèle, la fluorescence est détectée en temps réel par le thermocycleur (spécifiquement adapté a la qPCR) et est directement corrélée à la quantité d'ADN présent dans l'échantillon (i.e. donc au nombre de transcrits initiaux). La quantification peut se faire de manière relative en comparant la fluorescence de standard. échantillons, deux ou absolue en la comparant à un Cette méthode est très sensible (elle nécessite peu d'ARN au départ), et précise mais son débit est néanmoins limité par la nécessité de designer des amorces pour chaque gène et donc de connaître le génome *a priori*; il est cependant possible de multiplexer les réactions comme dans une PCR classique. La gPCR est encore très utilisée aujourd'hui, notamment pour valider individuellement les résultats obtenus par des méthodes haut-débit.

La méthode du 'Differential Display' (DD) (Liang and Pardee, 1992; Welsh et al., 1992) consiste à amplifier des ADNc avec des amorces aléatoires puis a séparer les amplicons par électrophorèse. L'intensité des bandes correspond alors à l'abondance des transcrits et peut être comparée entre différentes conditions. Les bandes peuvent également être extraites et séquencées individuellement. Comparées aux autres méthodes décrivant le transcriptome dans sa globalité, cette dernière a l'avantage d'être peu coûteuse et simple à mettre en place.

Hybridation

Ces techniques sont basées sur le principe des puces à ADN et possèdent donc les mêmes avantages et inconvénients. Elles nécessitent notamment de nombreuses étapes de normalisation dues aux variations des conditions expérimentales (pH, température, force ionique...), ainsi qu'une connaissance préalable du génome afin de dessiner la puce, et par conséquent ne permettent pas de découvrir de nouveaux gènes chez des génotypes variants. Par ailleurs, le bruit de fond et la saturation du signal empêchent une quantification fiable des gènes très faiblement ou fortement exprimés (Okoniewski and Miller, 2006). Les puces à ADN sont néanmoins peu coûteuses et simples à utiliser une fois le design initial réalisé. Il existe deux types de design qui diffèrent par la quantité d'informations qu'ils fournissent. Le 1^{er} type correspond aux puces pangénomiques pour lesquelles chaque sonde correspond a un gène cible en particulier et dépend entièrement de la qualité des annotations du génome utilisé pour le design (Schena et al., 1995). Le 2nd type est communément appelé 'tiling array' et utilise des sondes dont les séquences, généralement chevauchantes, représentent partiellement ou complètement le génome à haute densité. Le design de ces dernières est donc indépendant de l'annotation du génome et des possibles erreurs informatiques ou humaines. En fonction du protocole utilisé, ces puces permettent d'étudier des phénomènes complémentaires de la transcription, contribuant à une meilleure interprétation des résultats d'expression obtenus (sites de fixation des régulateurs, méthylation...).

L'hybridation des ADNc avec les sondes est détectée grâce à un marqueur fluorescent ou luminescent et l'expression est quantifiée à partir de l'intensité du signal. Disposant de marqueurs différents, deux échantillons peuvent alors être mélangés et comparés sur une même puce ; leurs ADNc sont alors en compétition pour les mêmes sondes et le différentiel d'expression entre les échantillons est calculé a partir du ratio de l'intensité du signal produit par les deux marqueurs (Shalon et al., 1996) (**Figure 14**). Alternativement, il est possible de comparer les résultats provenant de plusieurs puces après une normalisation des intensités se basant sur un gène de référence, typiquement un gène de ménage dont l'expression est constante dans toutes les conditions et qui ne présente pas de dégradation du signal significativement différente des cibles étudiées. La transcription étant un phénomène complexe, il est néanmoins fréquent que l'expression des gènes de référence choisis soit en réalité variable (Thellin et al., 1999).



Figure 14 - Principe d'une puce à ADN basée sur des ADNc (Miller et al. 2009).

Séquençage

Les méthodes de quantification de l'expression des gènes basées sur le séquençage ne nécessitent pas de connaissance préalable du génome et elles ont donc l'avantage, entre autres, de permettre l'identification de nouveaux gènes. Initialement, ces méthodes ne reposent que sur une séquence partielle des transcrits ('tags'). Des librairies d'ADNc sont ainsi séquencées aux deux extrémités (300-500pb) par Sanger et donnent lieu à la création de bases de données d'EST ('Expressed Sequenced Tags') (Adams et al., 1991). Ces fragments de séquences sont suffisamment uniques pour distinguer les transcrits, et la fréquence de chaque EST au sein de chaque librairie est utilisée pour définir leur niveau d'expression. Puisqu'elle nécessite des étapes de clonage et de séquençage par Sanger, cette méthode est coûteuse et relativement laborieuse. (**Figure 15**)

Plusieurs autres méthodes basées sur les tags furent développées par la suite. La méthode SAGE ('Serial Analysis of Gene Expression') (Velculescu et al., 1995), développée à l'origine dans le cadre de l'étude des cellules cancéreuse (John Hopkins University), est relativement complexe dans son principe comme dans sa mise en place, et constitue les prémices du séquençage en parallèle. Les ADNc sont fixés à des billes (Streptavidine) via leur queue polyT (complément du polyA des ARNm, la méthode est donc en général destinée à l'étude des eucaryotes du à la rareté des ARNm polyadenylés chez les procaryotes), puis clivés par une 1ère enzyme de restriction afin de fixer un adaptateur (NlaIII – 'Anchoring Enzyme'). Cet adaptateur contient lui-même un site de restriction d'une enzyme de type IIS clivant exactement 13pb en aval de ce site (BsmFI – 'Tagging Enzyme'). Le fragment détaché de la bille contient ainsi un tag de taille constante représentant la signature du transcrit. L'adaptateur est ensuite séparé du tag en réutilisant la 1ère enzyme de restriction (NlaIII). Finalement, les tags provenant de plusieurs ADNc sont concaténés par ligation, clonés, amplifiés et séquencés par Sanger. Bien que cette méthode repose encore sur le clonage et le séquençage Sanger, comme les ESTs, l'étape de concaténation équivaut à une parallélisation du séquençage et permet d'obtenir bien plus de tags en une seule réaction (Figure 16).



Figure 15 – Diversité nucléotidique des informations obtenues par séquençage dans le cadre d'analyses transcriptionnelles (Fullwood et al. 2009).



Figure 16 – Principe du SAGE (Modern Molecular Biology: Approaches for Unbiased Discovery in Cancer Research , Srinivasan Yegnasubramanian 2010).

Par la suite, la méthode SAGE a été améliorée fournissant la méthode MPSS ('massively parallel signature sequencing') (Brenner et al., 2000b). Les tags s'agrandissent grâce à l'utilisation d'une 'Tagging Enzyme' produisant des fragments de 20pb (MmeI). Apres clonage, les concaténâts de tags ne sont maintenant plus séquencés par Sanger, mais fixés de nouveau sur des billes. Les étapes de clonage et d'amplification rajoutent des tags « d'adressage » complémentaires d'« anti-tags » distincts fixés sur chaque bille afin de s'assurer qu'elles contiennent toujours les tags d'un même clone. Les billes sont ensuite triées sur une cellule microfluidique et séquencées avec une méthode de séquençage par ligation. Dans son ensemble, ce procédé permet un séquençage parallèle massif et produit ~20x plus de tags que par SAGE. La séquence est obtenue successivement par groupe de 4 nucléotides à l'aide d'adaptateurs fluorescents clivés après chaque cycle de ligation. Cette technique constitue l'origine des méthodes de 2^{nde} génération ; la compagnie Lynxgen Therapeutics l'ayant commercialisé fusionnera d'ailleurs avec Solexa qui deviendra plus tard Illumina.

Cependant, les méthodes SAGE et MPSS sont dépendantes d'enzymes de restriction pour générer les tags, aussi les transcrits qui ne posséderaient pas certains sites de restriction ne sont donc pas pris en compte dans l'analyse. De plus, la taille limitée des tags rend parfois difficile l'identification des gènes dont ils proviennent, si leur séquence est présente au sein de plusieurs gènes ou bien en présence d'épissage alternatif.

Avec le développement des méthodes de 2^{nde} génération, des méthodes de fragmentation (physiques ou chimiques) moins dépendantes de la séquence des ADNc sont utilisées. Plus important encore, le SGS permet de séquencer l'intégralité des ADNc et ainsi d'obtenir une quantité d'information bien plus importante (variations de séquences et structurelles) (Wang et al., 2009). Par exemple, en l'absence de génome de référence sur lequel aligner les lectures de séquençage, le transcriptome peut être directement assemblé *de novo*. L'amplification des ADNc n'est également pas obligatoire, mais son absence nécessite cependant de plus grandes quantités d'ARN de départ. Sans amplification, la quantification de

l'expression est directement basée sur le nombre de transcrits présents dans l'échantillon et séquencé pour chaque gène (signal numérique). Le SGS a ainsi une plage de détection, bien plus large que les puces à ADN (signal analogue) et peut distinguer des gènes très fortement ou très faiblement exprimés. La détection des transcrits rares (faiblement exprimés) nécessite néanmoins d'avoir une profondeur de séquençage (couverture) suffisante pouvant augmenter significativement le coût de l'analyse. Le protocole le plus fréquemment utilisé est celui du RNAseq sur la plateforme Illumina. Avec le séquençage de 3^{ème} génération, il est maintenant possible de séquencer directement les ADNc en intégralité sans passer par une étape de fragmentation.

Les données produites par les différentes méthodes d'analyses décrites ci-dessus requièrent des approches statistiques fondamentalement différentes. Les puces à ADN fournissent des intensités lumineuses suivants théoriquement une distribution continue (loi Normale), tandis que le séquençage produit un compte de tags ou de lectures suivant une distribution discrète (loi de Poisson, binomiale négative). Par conséquent, une méthode statistique développée pour les puces à ADN ne peut être directement utilisée pour analyser des données de comptage (Rodríguez-Ezpeleta et al., 2012). De façon similaire à l'évolution des méthodes d'assemblage lors de la transition du Sanger vers le SGS, les modèles statistiques au cœur de l'analyse des comptages, dérivées du séquençage, sont devenus significativement plus nombreux et complexes que ceux utilisés pour les puces à ADN du aux quantités de données produites. Ces modèles sont encore en développement aujourd'hui et de nouveaux modèles sont fréquemment proposés (approche bayésienne) sans qu'un consensus définitif n'existe sur la méthode la plus efficace (Soneson and Delorenzi, 2013).

b. Transcriptomique et spectre d'hôte chez les phytopathogènes

L'expression des facteurs de virulence et leurs régulations ont été vastement étudiés chez *R. solanacearum*, notamment à l'aide de gènes rapporteurs (Allen et al., 1997; Flavier et al., 1997; Huang et al., 1998; Genin et al., 2005; Monteiro et al., 2012; Zuluaga et al., 2013). En revanche, les travaux concernant le profil d'expression global du génome de *R. solanacearum* sont fragmentaires.

Une analyse de type IVET, basée sur une souche mutante dont l'auxotrophie pour le tryptophane était associée à la perte de virulence chez la tomate a permis d'identifier plus de 150 gènes exprimés durant l'infection (Brown and Allen, 2004). Par la suite, des travaux similaires ont été réalisés avec une puce à ADN et les auteurs ont comparé les profils d'expression chez deux souches appartenant à des lignées distinctes (phylotype I et IIB-1) colonisant l'hôte sensible (la tomate) ou cultivant un milieu de culture riche (CPG) (Jacobs et al., 2012). Cette comparaison a révélé que les gènes partagés par les deux souches ont un profil d'expression similaire chez la tomate ; parmi ces gènes, 2898 sont exprimés chez la tomate et 402 sont différentiellement exprimés par rapport au milieu riche (sur- ou sousexpression). Spécifiquement, ces travaux ont démontré que le T3SS était fortement actif in planta (à haute densité cellulaire) contrairement au modèle de régulation précédemment établi (Genin et al., 2005; Yoshimochi et al., 2009). Ces résultats furent validés indépendamment à l'aide d'un marqueur luminescent (Monteiro et al., 2012). Aucune analyse transcriptomique par séquençage à haut-débit n'a été effectuée à ce jour chez R. solanacearum, néanmoins les changements induits chez un hôte (l'arachide) au cours de l'infection ont été analysés par RNAseq (Chen et al., 2014).

Au delà des aspects fondamentaux sur la connaissance des mécanismes de la virulence, la transcriptomique peut également être mise à profit dans l'identification des mécanismes d'adaptation expliquant les variations de la gamme d'hôte des phytopathogènes. Par exemple, chez *Xanthomonas citri*, une bactérie monomorphe pathogène des agrumes, la comparaison de deux génotypes par RNAseq a révélé la

surexpression de régulateurs centraux de la virulence (T3SS, T2SS, flagelles, chimiotactisme) chez la souche possédant une gamme d'hôte restreinte d'une part et, d'autre part, la surexpression de facteurs d'adhésion ou de résistance au stress chez la souche possédant une gamme d'hôte large (Jalan et al., 2013). De plus, ces travaux ont identifié un nombre plus important de gènes différentiellement exprimés par rapport à une étude précédente basée sur l'analyse par puce à ADN dans les mêmes conditions expérimentales (Astua-Monge et al., 2005); illustrant ainsi la sensibilité accrue des méthodes SGS.

Chapitre 2 – Révision taxonomique du complexe d'espèces

Depuis la caractérisation de l'agent du flétrissement bactérien par E. F. Smith en 1896, sa classification n'a cessé d'évoluer en fonction des avancées techniques et méthodologiques. Aujourd'hui, la définition standard des espèces en bactériologie repose sur une combinaison de traits phénotypiques et d'analyses d'hybridation ADN-ADN (DDH). Depuis l'avènement du séquençage, la validité de ces méthodes en tant que mètre-étalons pour la classification des espèces est fréquemment remise en cause (Figure 17). La DDH présente notamment des problèmes de répétabilité dus à la complexité de la méthode. C'est une technique coûteuse et laborieuse à mettre en place du à la rareté des laboratoires la pratiquant encore. La DDH ne permet également pas la mise en place de bases de données incrémentales. A une échelle plus globale, la DDH ne mesure pas directement le degré de similarité mais la capacité de l'ADN à s'hybrider et ne fournit pas d'autres informations supplémentaires. Plusieurs problèmes inhérents à la DDH, furent d'ailleurs spécifiquement discutés lors d'analyses chez R. solanacearum (Palleroni and Doudoroff, 1971) et *R. syzygii* (Roberts et al., 1990), encore inclues à l'époque dans le genre Pseudomonas. Par ailleurs, ces deux études faisaient déjà mention de la diversité génétique inhabituelle de *R. solanacearum* et suggéraient l'urgence d'approfondir les connaissances des relations phylogénétiques entre les différentes souches de l'agent du flétrissement bactérien.

La révision proposée dans cette étude fait suite à une publication précédente de l'équipe qui suggérait la séparation du complexe d'espèce en trois espèces distinctes sur des bases génomiques (Remenant et al., 2011) : le phylotype I et III regroupés en une seule espèce, le phylotype II et IV formant chacun une espèce distincte. Cette proposition s'est vue concrétisée récemment par Safni et al. (Safni et al., 2014) avec plusieurs modifications par rapport a la proposition originale, en particulier s'agissant des souches types proposées mais surtout pour ce qui concerne les noms d'espèces proposés afin de respecter les règles taxonomiques internationales



Figure 17 – Evolution des méthodes de classification taxonomique au cours du temps.

(Garrity et al., 2005). La classification des phylotypes en trois nouvelles espèces est identique, le phylotype I et III deviennent *R. pseudosolanacearum* sp. nov.; le phylotype II reste *R. solanacearum* car c'est dans ce groupe qu'est assigné la souche type; le phylotype IV devient *R. syzygii* – car le nom d'espèce est toujours valide d'un point de vu taxonomique – et comprend trois sous-espèces afin de décrire la diversité phénotypique de ce groupe particulier : les souches précédemment désignées comme *R. solanacearum* deviennent la sous-espèce *indonesiensis* subsp. nov., les souches BDB sont désignées comme la sous-espèce *celebensis* subsp. nov. et les *R. syzygii* originales deviennent la sous-espèce *syzygii* subsp. nov.. Safni et al. ont démontré la validité de cette séparation de manière polyphasique, avec des méthodes historiques regroupant des analyses DDH et des profils phénotypiques à haut-débit. Notre étude vient supporter cette révision via des techniques modernes reconnues par la communauté internationale se basant sur le séquençage à haut débit et une technique plus exploratoire reposant sur des profils protéomiques obtenus par spectrométrie de masse (Figure 18). Trois algorithmes distincts ont été utilisés pour obtenir ces valeurs : ANI (Average Nucleotidic Identity) qui a été une des premières méthodes répandues suggérant que les distances génomiques pouvaient remplacer la DDH pour la délimitation des espèces (Konstantinidis and Tiedje, 2005); MUMi (Maximum Unique Matches index) qui repose sur les mêmes principe que l'ANI mais améliore entre autre le temps de calcul (Deloger et al., 2009) ; GGDC (Genome to Genome Distance Calculator) qui est une méthode encore mise à jour récemment et qui propose des valeurs de DDH prédites in silico (Auch et al., 2010).

Ces travaux ont fait l'objet d'une publication intitulee : « Further evidences for the division of the plant pathogen *Ralstonia solanacearum* into three species inferred by genomic and proteomic » soumise en fevrier 2015 a la revue Systematic Applied Microbiology [IF 3,51].
Matrix-Assisted Laser Desorption/Ionization-Time Of Flight



Figure 18 - Méthodologie utilisée pour produire un arbre à partir de données protéomiques.

1 Additional evidence for the division of the plant pathogen *Ralstonia solanacearum*

- 2 into three species inferred through genomic and proteomic analyses.
- Philippe Prior ^{a, d,*,1}, Florent Ailloud ^{a, b,1}, Beth L. Dalsing ^c, Benoit Remenant ^a, Borja
 Sanchez ^{d, e}, and Caitilyn Allen ^c
- 5
- 6 ^a UMR PVBMT Peuplements Végétaux et Bioagresseurs en Milieu Tropical, CIRAD,
- 7 Saint Pierre, La Réunion, France
- ^bAnses Plant Health Laboratory (LSV), 7 chemin de l'IRAT, Saint-Pierre, La Réunion,
 France
- ^c Department of Plant Pathology, University of Wisconsin-Madison, 1630 Linden Drive,
 Madison, WI 53706, USA
- ^d Department of Plant Health and Environment (SPE), INRA, France.
- ^e Department of Analytical and Food Chemistry, University of Vigo, Ourense, Spain
 15
- 16

13

- 17 *Corresponding author: UMR PVBMT Peuplements Végétaux et Bioagresseurs en
- 18 Milieu Tropical, CIRAD, Saint Pierre, La Réunion, France. E-mail address:
- 19 <u>philippe.prior@cirad.fr</u> (P. Prior)
- 20 ¹Both authors contributed equally to this study.

21 Abstract (214 words)

The increased availability of genome sequences has advanced the development of
genomic distance methods to describe bacterial diversity. Results of these fast-evolving
methods are highly correlated with those of the historically standard DNA-DNA
hybridization technique. They are thus a technically accessible replacement for species

- 26 delineation. Members of the Ralstonia solanacearum group cause bacterial wilt diseases
- 27 of many different plants. These diverse and widespread pathogens form a highly
- 28 heterogeneous species complex consisting of four genospecies, or phylotypes. We used
- 29 three different methods to compare the complete genomes of 29 strains from the R.
- 30 *solanacearum* species complex. In parallel we profiled the proteomes of 74 strains using
- 31 Matrix-Assisted Laser Desorption/Ionization-Time of Flight Mass Spectrometry
- 32 (MALDI-TOF-MS). Proteomic profiles together with genomic sequence comparisons
- 33 consistently and comprehensively described the diversity of *R. solanacearum*. In
- 34 addition, genome-driven functional phenotypic assays demonstrated that *R*.
- 35 *solanacearum* strains in phylotypes II and IV, which lack the NosZ nitrous oxide
- 36 reductase, do not produce dinitrogen gas from nitrate. Additionally, strains in phylotype I
- and III can grow anaerobically on nitrate, indicating that they reduce nitrate to nitrite.
- 38 Together, the results of these studies support the proposed division of the *R*.
- 39 solanacearum species complex into three species, consistent with recent literature, and
- 40 demonstrate the utility of proteomic and genomic approaches to delineate bacterial41 species.
- 42
- Keywords: Ralstonia solanacearum, bacterial wilt, plant pathogen, taxonomy, genomics,
 proteomics¹

- BDB: Blood Disease Bacterium
- DDH: DNA–DNA hybridization

ANI: Average Nucleotide Identity

GGDC: Genome-to-Genome Distance Calculator

MALDI-TOF: Matrix-assisted laser desorption/ionization-Time of flight

MLST: Multi Locus Sequence Typing

MUM: Maximum Unique Matches

RSSC: Ralstonia solanacearum species complex

45 Introduction

46 Thousands of genetically distinct strains within the Ralstonia solanacearum species

47 complex (RSSC) cause bacterial wilt diseases in plants. These bacteria colonize the

48 xylem tissue of host plant vascular systems, causing stunting, wilting, yield reduction,

and death. This pathogen group has major economic and social impact worldwide [1, 2].

50 Members of the RSSC can collectively infect over 250 hosts in 54 botanical families and

51 include: *R. solanacearum* strains, which collectively infect a broad host range and are

52 typically soil-borne; *R. syzygii*, a spittlebug-transmitted pathogen that causes Sumatra 53 disease in cloves; and the Blood Disease Bacterium (BDB), an unclassified organism

responsible for the pollinator-transmitted Blood Disease of bananas and plantains in the

55 Philippines.

56 Smith first described the morphological and chemotaxonomic characteristics of the

57 bacterial wilt pathogen as *Bacterium solanacearum*, and this species has most recently

been placed in the genus *Ralstonia* [3, 4]. The BDB was described and named

59 *Pseudomonas celebensis* in 1921 [5, 6]. However this name lost it's standing in

60 nomenclature when the original strain got misplaced and could thus not serve as an

61 authentic type matching the description of the pathogen. The Sumatra disease pathogen,

62 originally described as *Pseudomonas syzygii*, was placed in a separate species in the

63 genus *Ralstonia* based on 16S sequences and DNA–DNA hybridization (DDH) data

64 showing substantial divergence from *R. solanacearum* [7]. However, the DDH study that

65 concluded *R. syzygii* should be placed in a separate species was based on a comparison

66 with *R. solanacearum* $K60^{T}$, a phylotype II strain that is quite divergent from phylotype

67 IV at the phenotypic and genotypic levels.

68 DNA–DNA hybridization has been used to distinguish species since the 1960s, and this

69 technique has contributed to the modern bacterial species concept [6, 8]. However,

because complete sequenced genomes contain significantly more information than can be

inferred from the results of DDH, this technique can now be replaced with bioinformatics
methods that take advantage of the full genetic features of different microbes [9, 10].

72 methods that take advantage of the full generic features of different incrobes [9, 10].
 73 Early analyses based on the single-gene phylogeny of the conserved *egl, mutS, hrpB* or

74 ITS sequences divided the RSSC into four distinct genospecies, known as phylotypes,

75 corresponding to strain geographic origin: phylotype I (Asia), phylotype II (Americas),

76 phylotype III (Africa), and phylotype IV (Indonesia and Japan) [11-14]. The phylogenetic

77 structure of the RSSC was subsequently confirmed in an extensive series of genomic

78 studies involving a large array of analytical methods from microsatellites and MLST to

79 microarrays [12, 15, 16].

The analysis of the complete genome sequences of several strains in the RSSC provides
strong evidence supporting the phylotype structure [8, 11, 17-19]. These data reveal a

81 strong evidence supporting the phylotype structure [8, 11, 17-19]. These data reveal a 82 degree of evolutionary divergence among the phylotypes that warrants the division of the

RSSC into three species, as previously suggested [18]. Recently, Safni et al. (2014) [20]

supported this taxonomic revision, suggesting an amendment of the descriptions of the

supported this taxonomic revision, suggesting an amendment of the descriptions of the

85 RSSC based on a polyphasic approach: *R. pseudosolanacearum* sp. nov., corresponding

to phylotypes I and III, and *Ralstonia syzygii*, corresponding to phylotype IV. Based on differences in pathological phonotype, *P*, graviti is further divided into three subspacies

87 differences in pathological phenotype, *R. syzygii* is further divided into three subspecies.

- 88 The broad host-range soil-borne strains are renamed *R. syzygii* subspecies indonesiensis
- subsp. nov. The unclassified banana Blood Disease Bacterium is named *R. syzygii*
- 90 subspecies *celebesensis* subsp. nov. and *R. syzygii*, which causes Sumatra disease in
- 91 cloves, is renamed *R. syzygii* subspecies *syzygii* subsp. nov. Finally, phylotype II strains
- 92 (from the Americas), which include the species type strain $K60^{T}$ (=ATCC11696^T
- 93 =LMG2299^T), remain in *R. solanacearum*.

94 In the present study, we used a combination of genomic and proteomic methods to

- 95 unambiguously delineate the three species within the RSSC. We formally examined these
- 96 methods for correspondence to the recent reclassification of this taxonomically disputed
- 97 organism into three distinct species, consistent with Safni *et al.* (2014). This work
- 98 extends former research by providing tools for the rapid identification and classification
- 99 of new isolates into species and subspecies without the need to rely on archaic methods
- 100 including DDH.

101 Materials and methods

- 102 The sequenced strains used in the present study are listed in Table 1. The strains used for
- 103 the proteomic analyses are listed in Supplemental Table 2. The phylotype placement of
- all strains was confirmed using the multiplex PCR method [13].
- 105 Genomics.
- 106 The complete and assembled genome sequence data used here are publicly available via
- 107 the MicroScope web interface at www.genoscope.cns.fr/agc/microscope/ralstoniascope.
- 108 The Average Nucleotide Identity (ANIb) between genomes was calculated according to
- 109 Konstantinidis and Tiedje [21], and the genomic distances were obtained after subtracting
- 110 the ANIb values from 1. The Maximal Unique Matches index (MUMi) distances between
- 111 genomes were calculated using the Perl script developed by Deloger et al. [22] using
- 112 MUMmer genome alignment software [23]. The Genome-to-Genome Distance
- Calculator (GGDC) was used as previously described [24]. The DDH values were
 derived from the GGDC distances using formula 2 [24]. A phylogenetic network derive
- derived from the GGDC distances using formula 2 [24]. A phylogenetic network derived from the distance matrices produced with all three methods was created using SplitsTree4
- 116 software [25]. Distances matrices are available in **Supplemental Table 1**.
- 117 Anaerobic inorganic nitrogen metabolism assessments.
- 118 Nitrate respiration and complete denitrification were assessed using slightly modified
- 119 VDM medium [26, 27]. To decrease nitrate-independent anaerobic growth, we used
- 120 casamino acids instead of yeast extract [28]. Additionally, we omitted nitrate from the
- base medium. This was done to allow assays to be conducted with and without nitrate
- under otherwise similar conditions. Where specified, 30 mM NO_3^- (the concentration found in host plant xylem sap) was added in the form of filter sterilized KNO₃ [28].
- 123 found in nost plant xylem sap) was added in the form of filter sternized KNO₃ [28]. 124 1.5mL of this modified VDM (\pm /- NO₃⁻) was inoculated with a specified bacterial strain
- 125 to a starting O.D.₆₀₀ of \sim 0.001 (\sim 1x10⁶ CFU/mL). Tubes were incubated without
- 126 agitation at 28 °C under anaerobic conditions in a BD GasPak anaerobic system. 72 hours
- 127 post inoculation, O.D.₆₀₀ measurements were taken from each culture. Two to four

- 128 biological replicates were conducted per strain, per treatment $(+/-NO_3)$. To determine if
- 129 nitrate respiration contributed to anaerobic growth, O.D.₆₀₀ data were compared between
- 130 + and - NO₃⁻ treatments for each strain and depicted as a ratio. A ratio above 1 indicates
- 131 that the strain grew better anaerobically when provided with NO₃. A ratio of 1 or below
- indicates that the addition of NO_3^- did not enhance anaerobic growth, and that the strain 132
- 133 did not respire with NO₃⁻ under the conditions tested. Additionally, all cultures were 134 visually assessed (\pm bubbles) over the course of 96 hours for production of dinitrogen gas,
- 135
- the end product of complete denitrification [26, 29].
- 136 Analysis of denitrification genes.
- 137 Presence or absence of homologs involved in denitrification were determined in all
- 138 sequenced strains (Table 1) using the MicroScope web interface and BLAST [30] to look
- 139 for loci identified in the GMI1000 strain: fnr (RSc1283); narX (RSp0979); norR
- 140 (RSp0959); rpoN1 (RSc0408); nosR (RSp1369); a predicted nitric oxide metabolism-
- 141 related gene labeled hypreg1 (RSp1504); nsrR (RSc3397); nnrS (RSc3399); norA
- 142 (RSp0958); narG (RSp0974); nosZ (RSp1368); aniA (RSp1503); and norB (RSp1505).
- Identity values were computed with the R package seqinr [31] after aligning amino-acid 143
- 144 sequences with MUSCLE [32].
- 145
- 146 Bacterial typing using Matrix-Assisted Laser Desorption Ionization Time-Of-Flight Mass 147 Spectrometry.
- 148 Seventy-three strains belonging to different phylotypes of the *Ralstonia solanacearum*
- 149 complex species were characterized at the proteomic level using Matrix-Assisted Laser
- 150 Desorption Ionization Time-Of-Flight Mass Spectrometry (MALDI-TOF MS). Ralstonia
- 151 eutropha LMG 1199 was included in the analysis as an outgroup (Suppl. Table 2).
- 152 Bacterial strains were grown on Kelman broth supplemented with agar for 48 h at 28°C.
- 153 For whole-cell protein extraction, 1 µL of the bacterial biomass was collected and
- 154 resuspended in a solution containing 50% (v/v) acetonitrile (Acros Organics, Fair Lawn, 155 NJ, USA) and 1% (v/v) trifluoroacetic acid (Sigma-Aldrich, Saint Louis, MO, USA) in
- 156 Milli-Q® ultrapure water (EMD Millipore Corporation, Billerica, MA, USA). The
- suspensions were vortexed twice for 10 s and centrifuged at 20,000 g for 10 min at RT. 157
- 158 The supernatants were transferred and aliquoted into new tubes and stored at -20°C until
- 159 further analysis.
- 160 One microliter of the bacterial extracts was mixed with 1 μ L of a saturated solution of α -
- 161 cyano-4-hydroxycinnamic acid (Sigma-Aldrich), which was used as a matrix. The
- 162 resulting sample/matrix mixture was deposited onto a stainless plate, dried at room
- 163 temperature, and introduced into the MALDI-TOF MS instrument for analysis. The mass 164 spectra profiles were obtained using a bench-top Microflex[™] MALDI-TOF from Bruker
- 165 Daltonics, including the Flex Control and Flex Analysis v3.3 software, at the
- 166 Bacteriology Division of the CHU of St. Pierre, La Réunion. All spectra were obtained in
- 167 linear positive-ion mode with an m/z range of 2,000-20,000 Da. Each spectrum was
- 168 calculated as the sum of 320 accumulated laser shots obtained after a spiral trajectory of
- 169 the laser. For each sample, two bacterial extracts were obtained and measured in

- duplicate, and all the spectra were calibrated using a standard preparation of *Escherichia*
- 171 *coli* DH5α, according to Bruker Daltonics.
- 172 All bacterial spectra were analyzed using FlexAnalysis software (Bruker Daltonics) to
- 173 generate peak lists for each species, and only peaks with a relative intensity greater than
- 174 2% were considered for cluster analysis. The peak lists were exported to a CSV file,
- exported to single files using a custom macro and loaded onto the SPECLUST web-
- service (http://bioinfo.thep.lu.se/speclust.html) to obtain a consensus peak list for all
- 177 strains considered. For the consensus peaks, a peak match score (σ) width of \pm 3 Da was
- 178 considered.
- 179 *Phylogenetic reconstruction using the MALDI-TOF data.*
- 180 The consensus peak list was formatted into a sequential Nexus binary file and loaded into
- 181 MrBayes 3.2.2 software (http://mrbayes.sourceforge.net/). Phylogeny was obtained
- 182 through Bayesian inference using the restriction data type (two states: absence or
- 183 presence of a peptide denoted by a 0 or a 1, respectively), assuming that the frequencies
- 184 of the two possible states had a Dirichlet (1.00, 1.00) prior. Bayesian analysis was
- 185 performed in two runs using 8 Markov chains and 3,000,000 generations. The potential
- scale reduction factor implemented in MrBayes 3.2.2 was used as a convergence
- 187 diagnostic. A majority-rule consensus tree (50%) was obtained after discarding 25% of
- the initial trees (burn-in=0.25) generated before the stabilization of the log likelihood
- values of the data plotted against the number of generations. The trees were subsequently
- edited using FigTree v1.3.1 (http://tree.bio.ed.ac.uk/software/figtree/).
- 191 Results and Discussion

192 RSSC exhibits phenotypic diversity

- 193 Safni et al. [20] analyzed the RSSC using phenotype microarrays and identified major
- 194 differences in the core metabolisms of each phylotype, supporting the idea that *R*.
- solanacearum can be divided into multiple species based on biological data. In the
- 196 present study, we focused on the denitrification metabolic pathway, as it is a biologically
- 197 relevant phenotypic trait [28] related to known genetic features that differentiate
- 198 phylotypes I and III from the other *R. solanacearum* strains.

199 All tested strains in phylotypes I and III underwent complete denitrification and could 200 respire on nitrate, as demonstrated by the production of nitrogen gas and significant 201 growth when incubated anaerobically in nitrate-containing medium (Fig. 1A). In 1990, 202 Hayward recognized and examined the variability of anaerobic nitrogen metabolism 203 between *R. solanacearum* strains [25]. However, the biovar sub-classification system, in 204 use at the time, did not correspond to the phylogenetic relationships among RSSC strains. 205 No clear patterns differentiated biovars by anaerobic nitrogen metabolism and, thus 206 denitrification was not considered a useful trait for strain typing. The reclassification of 207 strains into phylotypes based on phylogenetic analyses revealed that this metabolic trait is 208 a defining characteristic of RSSC subgroups. Denitrification is an anaerobic respiration 209 process that allows strains to use nitrate as a terminal electron acceptor in order to grow 210 under anaerobic conditions. Nitrate (NO_3) is converted successively to nitrite (NO_2) .



Figure 1 - Denitrification in RSSC A. Growth and production of nitrogen gas under anaerobic condition. Values represent the ratio of $O.D_{.600}$ readings following 72 hours of anaerobic incubation in VDM + NO_{3} · vs - NO_{3} ·. A value above 1 indicates that in the presence of NO_{3} · a strain reached higher optical densities than in the absence of NO_{3} ·, indicating NO_{3} · respiration enhanced growth. A value above the arbitrary threshold of 2 meets our cut-off for proposed biological significance. Strain names in green and green '+' s indicate N_{2} gas was produced within 96 hours of anaerobic inoculation in VDM + 30 mM NO_{3} ·. Production of N_{2} indicates that the strain completed the full denitrification pathway. Bars indicate standard error. Data represent the means of 4-6 biological replicates. B. Summary of the presence/absence of denitrification genes. Black cells indicate the presence of a gene in all the sequenced strains of this group while white cells indicate its absence.

211 nitric oxide (NO), nitrous oxide (N₂O), and finally nitrogen gas (N₂) in a series of four

reactions catalyzed by the products of the *narG*, *aniA*, *norB* and *nosZ* genes, respectively.

213 The production of N_2 reflects the nitrous oxide reductase activity encoded by *nosZ*. 214 Notably, this gene and nitrous oxide reductase activity are both absent from all phylotype 215 II and IV strains evaluated (Fig. 1B). Moreover, respiration on nitrate seems to be 216 dependent on *nosZ* since it is the only core catalytic subunit encoding gene missing from 217 the denitrification pathway in *R. solanacearum* strains evaluated from phylotypes II and 218 IV. However, the same is not necessarily true of phylotypes I and III, because a nosZ219 deletion mutant can respire and grow on nitrate under anaerobic conditions [28]. Thus, 220 denitrification appears to be a complex process not yet fully understood. Indeed, up to 221 nine regulators and predicted inorganic nitrogen metabolism-related proteins are known 222 to be involved in denitrification in other organisms are found in RSSC. Some, like NosZ, 223 are present only in phylotypes I and III (NorA, NosR, NorR), and could be involved in 224 the expression of additional genes required for anaerobic respiration. For example, NorA 225 and NorR are both NO binding proteins in *R. eutropha* [33] and NO is an important 226 intermediate molecule produced prior to N₂ production in the denitrification pathway. 227 Furthermore, regulators present in all the RSSC do not exhibit a similar degree of 228 conservation across phylotypes. While the amino acid identities of RpoN1, Fnr, and NsrR 229 are greater than 90% across all phylotypes, the NnrS, NarX and Hypreg1 homologs only 230 share ~70% amino acid identities between phylotype I/III and phylotype II/IV. Further 231 characterization of these regulators would be required to better understand the observed 232 phenotypes.

233 Our functional studies of nitrogen metabolism conflict with those of Safni et al. in two 234 important respects. Safni *et al.* reported that most of the phylotype II strains and many 235 strains from phylotype IV produced dinitrogen gas. We did not detect N₂ gas production 236 from any tested phylotype II or IV strains. Considering that this function depends on 237 *nosZ*, a gene that is absent from all sequenced strains of these two phylotypes, the results 238 from the nitrate-to-gas experiment presented by Safni et al. likely reflect experimental 239 errors. Additionally, the authors stated that phylotype I strains are incapable of anaerobic 240 nitrate reduction to nitrite even though the same strains are described as producing N_2 gas 241 from nitrate; this is physiologically impossible because the production of dinitrogen gas 242 cannot occur without the initial conversion of nitrate to nitrite under the conditions tested 243 (nitrate as the sole terminal electron acceptor and inorganic nitrogen species). Our finding 244 that phylotype I and III strains can respire on nitrate anaerobically offers functional 245 evidence that they do reduce nitrate to nitrite. This experimental evidence is consistent 246 with the genomic data indicating the presence of NarG nitrate reductase in all sequenced 247 phylotype I strains. The formal descriptions of the species proposed by Safni et al. should 248 be revised to indicate that phylotype II and IV strains do not produce N₂ gas from nitrate, 249 and that phylotype I strains do reduce nitrate to nitrate.

250 RSSC exhibits genomic diversity

251 The 16S rRNA gene sequences of *R. solanacearum* strains are more than 97% identical,

suggesting that this group forms a single species that is distinct from its close relative *R*.

253 eutropha [4]. However, 16S rRNA sequences do not always accurately reflect similarities

254 at the whole-genome level and cannot distinguish between recently diverged species [34, 255 35]. Moreover, the identity threshold has not been universally accepted, and distinct 256 species with 98% identical 16S rRNA sequences have been described [36]. DDH has 257 been historically used for species delineation, and a 70% DNA–DNA similarity is 258 traditionally used to define species. Recently, Safni *et al.* provided evidence that R. 259 solanacearum can be divided into 3 species based on DDH values. In a complementary 260 approach, we evaluated the taxonomy of *R. solanacearum* using genomic and proteomic 261 data. As a method, DDH has significant drawbacks: it is technically difficult, is 262 performed only in a few specialized laboratories, and is prone to experimental errors [37]. 263 DDH assays can only measure the potential for hybridization between purified DNA 264 from two organisms, without regard to biological function. Thus, the 70% DDH criterion 265 does not correspond to 70% shared orthologous genes or even 70% sequence identity 266 [38]. Strains showing more than 70% DDH can possess up to 21% divergent gene content, equivalent to around 1000 genes in a typical 5.3 Mb R. solanacearum genome [39]. With 267 268 the recent development of in silico comparative methods using complete genome 269 sequences, DDH is no longer the best, most reliable method for determining sequence 270 identity.

271

In a previous study [18], we proposed division of the RSSC into 3 genomospecies based
on a genome-to-genome comparison using Average Nucleotide Identity (ANI) analyses
and 8 strains. In the present study, we included 15 additional genomes in the ANI
analysis and compared it to two recent methods showing a better correlation with DDH:
the Maximum Unique Matches index (MUMi) and the Genome-to-Genome Distance
Calculator (GGDC) [10, 21, 22, 24] (Supplemental Table 1).

278 Briefly, ANI detects the level of conservation or similarity of the total genomic sequences 279 shared between two strains based on the identification of homologous fragments of fixed 280 length using the BLAST algorithm. Strains with ANI >95% are considered as belonging 281 to the same species, consistent with the 70% DDH criterion [10, 21, 39-42]. Similar to 282 DDH, ANI accounts for the variability in conserved gene content and does not always 283 reflect differences between closely related strains. Thus, strains with similar ANI values 284 can have similar or dissimilar gene content during intraspecies comparison [43]. The 285 MUMi algorithm overcomes this issue and accounts for both the variability of 286 homologous gene content and the gain and loss of DNA. MUMi distances are derived 287 from a list of maximum unique matches (MUMs) of a given minimal length shared 288 between two genomes and the average length between genomes. Because this technique 289 uses a fast algorithm to detect MUMs, MUMi is significantly faster than ANI. A MUMi 290 value of 0.33 ± 0.03 corresponds to an ANI value of 95%. Moreover, the GGDC method 291 has been recently revised, showing the highest correlation with wet-lab DDH [24, 44]. 292 The GGDC also infers in silico DDH values from genomic distances; therefore, a similar 293 70% threshold can be used. Although this method is based on principles similar to ANI 294 and MUMi, GGDC uses a different set of formulas to estimate genomic distances.

295 The ANI values obtained from pairwise comparisons between all genomes are presented

in Supplemental Table 1. The 29 strains analyzed in the present study fall into three

297 distinct groups. The first group includes strains from phylotypes I and III. The second

group comprises phylotype II strains, divided into subgroups IIA (containing the current *R. solanacearum* type strain, $K60^{T}$) and IIB. The last group includes phylotype IV strains (PSI07, BDB R229 and *R. syzygii* R24), originally described as a separate species before the establishment of the species complex. These ANI results are consistent with a previous analysis of a smaller group of genomes [18].

303 The genomic distances calculated using the MUMi algorithm are presented in 304 Supplemental Table 1. This method separates the RSSC into 3 or more species 305 depending on how strictly the 0.33 ± 0.03 criterion is applied. Consistent with the ANI 306 analysis, this method identifies two distinct species: one containing phylotype IV, and 307 one containing phylotypes I and III. However, the delineation of phylotype II as a single 308 species was not definitive, and the genomic distances were $< 0.33 \pm 0.03$ in 100% of the 309 strains within subgroups IIA and IIB. Notably, the distances between IIB strain UW551 310 and 5 of the 6 IIA strains were above the threshold (0.37-0.40). However, MUMi values 311 above 0.33 were also observed in other species. For example, although *Pseudomonas* 312 syringae has an average intraspecies MUMi of 0.7, this species is considered distinct 313 from other *Pseudomonas*, with an average intragenus MUMi of 0.9 [22].

314 In silico DDH values inferred using the GGDC algorithm are presented in Supplemental 315 Table 1. According to the traditional 70% DDH criterion, GGDC distinguishes 5 species 316 within RSSC with phylotypes I, III and IV assigned to a single species and phylotype II 317 divided into 2 species corresponding to the IIA and IIB subgroups. Thus, GGDC more 318 clearly differentiates between closely related strains. Although GGDC divides the RSSC 319 into more species than ANI and MUMi, the raw result patterns are consistent between all 320 3 methods. As previously observed with the MUMi distances, IIA and IIB strains are 321 definitely divergent at the whole-genome level. The ANI values between phylotypes I 322 and III, or subtypes IIA and IIB, were approximately 96%, while the ANI values within 323 the species predicted using GGDC ranged from 97 to 99%. Moreover, a phylogenetic 324 network derived from the ANI, MUMi and GGDC distance matrices was built using 325 SplitsTree software. The results showed no obvious ambiguities, confirming that all three 326 genome sequence-based methods give broadly consistent results (Fig. 2).

327 The ANI, MUMi and GGDC methods are all based on whole-genome comparisons and 328 have been shown to correlate well with the traditional standard method, DDH. 329 Nonetheless, the RSSC can be divided into three to five species depending on how the 330 genomic distances are calculated and the criteria used. Taken together, the outputs of 331 these techniques illustrate the difficulty of consistently delineating species among closely 332 related strains. Based on phenotypic data, ANI and MUMi distances adequately reflect the level of biological variability within the RSSC, with a three species division in which 333 334 phylotypes I and III cluster together, and phylotypes II and IV are further apart.

- 335 *RSSC exhibits proteome diversity*
- A total of 73 bacterial strains representing the four phylotypes were subjected to

337 comparative proteomic analysis as a complementary method to the genome-based

- analyses presented above. Protein mass spectra corresponding to each strain were
- 339 obtained using MALDI-TOF and clustered using SPECLUST software [45]. This



Figure 2 - Phylogenetic network derived from the distance matrices generated using all three methods and the SplitsTree4 software. The orange, blue and green cells represent strains clustered into species using the criteria specific to the ANI, MUMi and GGDC methods, respectively.

- 340 generated a list of common peaks represented as inter-sample consensus m/z values. The
- best results were achieved using a "within peak match score (σ)" of 3 Da, as defined in
- 342 the SPECLUST documentation. The consensus spectra matrix was translated to a binary
- 343 matrix in which the absence/presence of a consensus peak in all strain profiles was
- represented as 0 or 1, respectively. This binary matrix was used to infer the phylogenetic
- relationships among the strains with the MALDI-TOF data and Bayesian analysis using
- 346 MrBayes v3.2.2 software [46].
- The MALDI-TOF approach has previously been used for bacterial identification [47].
- 348 Mass fingerprinting has been used as a simple, quick and reproducible method for
- bacterial identification through the generation of large spectral databases [48].
- 350
- Taxonomically, molecular typing using protein profiles has been useful for bacterial
- classification at the species and subspecies levels [49, 50] and at the strain level,depending on the type and class of bacterial group considered [51]. In the present stud
- depending on the type and class of bacterial group considered [51]. In the present study, a combination of MALDI-TOF profiling, consensus mass peak lists, and Bayesian
- inference was used to cluster the 73 *Ralstonia* strains into three groups with strong branch
- support. The first cluster contained phylotypes I and III, whereas the second cluster
- 357 contained phylotypes IIA and IIB, and the third cluster contained phylotype IV (**Fig. 3**).
- These results were consistent with the findings of the genetic analysis, supporting the
- 359 division of *R. solanacearum* into three species.
- 360
- 361 Phenotypic, genomic and proteomic data converge on a three-species model
- 362 The taxonomic classification of *R. solanacearum* has changed repeatedly over the last 50 363 years, grouping strains with divergent ecological, geographical, genetic and phenotypic 364 profiles, including many pathological variants. Safni et al. recently used DDH on the 365 taxonomic revision of the RSSC, proposing the division of this complex into three 366 distinct species. Among other emerging classification methods, modern techniques, such as 2nd generation sequencing, have provided great opportunities to understand the 367 368 phylogenetic relationships between strains and to question the relevance of the current 369 taxonomy of this species complex. Moreover, phenotypic data can be directly correlated 370 with genomic content in order to better understand the traits used to delineate species. 371 Using a combination of phenotypic analyses, whole-genome comparisons and proteomic 372 profiling, we provide additional information on the relationships between *R*. 373 solanacearum strains, supporting the proposed three-species delineation of the current 374 RSSC. The first species includes phylotypes I and III. The strains from these two 375 phylotypes undergo denitrification, among other unique phenotypic properties, and are 376 genetically closely related. They are, however, divergently adapted to temperatures 377 because phylotype III strains are primarily observed in temperate highlands, while 378 phylotype I strains are often isolated in tropical lowlands.
- The second species corresponds to phylotype II. The strains in this phylotype present a certain degree of genomic divergence, resulting in the vague delineation of species based on genomic distances. Nonetheless, every strain belonging to phylotype II evaluated todate exhibits similar phenotypic properties and could therefore be considered a single species. The third species comprises the phylotype IV strains currently classified as *R*.



Figure 3 - Majority-rule consensus tree based on the presence/absence of a consensus MALDI-TOF peak list obtained using MrBayes software. Probabilities are indicated along the main branches. Strains colored in red indicate sequenced strains.

- *solanacearum*; *R. syzygii*, which is transmitted through tube-building *Hindola* spp.
- 385 cercopoid insects, with a host range limited to clove trees (Sumatra disease); and BDB,
- the causative agent of banana wilt diseases in Indonesia. Despite their strikingly different
- biological lifestyles [52], these strains are genetically related and display common core
- 388 metabolic activities. *R. solanacearum*, *R. syzygii* and BDB present different geographical
- distributions and pathogenic potential. Moreover, because these groups are easily
- 390 genetically distinguishable, the members of this third group could be considered
- 391 subspecies.

392 Conclusions

- 393 Extensive biological, phenotypic, and genetic data demonstrate that *R. solanacearum* is
- too diverse to be considered a single species. The modification of the taxonomy of this
- organism is necessary to recognize three phylogenetically distinct groups with different
- 396 biological properties and evolutionary relationships. Newly isolated bacterial wilt strains
- 397 can readily be assigned to the proposed scheme using existing molecular methods [13].
- 398These changes will benefit many different applications, including breeding plant
- resistance to bacterial wilt, the identification of new pathological variants, management
- 400 of quarantine containment and the development of diagnostic tests.

401 Acknowledgments

- 402 We gratefully acknowledge Boris Vitnazer for providing some of the IIB-1 genomes and
- 403 Carolee Bull for valuable discussions. This research was supported through INRA,
- 404 CIRAD and the University of Wisconsin-Madison College of Agricultural and Life
- 405 Sciences. The authors would like to thank Aurélie Lajus and Claudine Médigue
- 406 (Genoscope, France) for technical support and A. Michault from CHU de La Réunion
- 407 Groupe Hospitalier Sud Réunion for generously providing the MALDI-TOF-MS
- 408 instrument. Borja Sánchez received funding from the INRA and a European Union
- 409 AgreenSkills postdoctoral fellowship (grant agreement n° 267196).

410 References

- 411
- [1] T. Denny, Plant pathogenic Ralstonia species, in: S.S. Gnanamanickam (Ed.) Plant-412
- 413 Associated Bacteria, Springer Netherlands, Dordrecht, The Netherlands, 2006, pp. 573-414 644.
- 415 [2] A.C. Hayward, Biology and epidemiology of bacterial wilt caused by *Pseudomonas* 416
- solanacearum, Annu Rev Phytopathol, 29 (1991) 65-87.
- 417 [3] E.F. Smith, A bacterial disease of tomato, eggplant, and Irish potato (Bacterium
- 418 solanacearum nov. sp.). USDA Div. Veg. Physiol. Pathol. Bull., 12:191 (1896).
- 419 [4] E. Yabuuchi, Y. Kosako, I. Yano, H. Hotta, Y. Nishiuchi, Transfer of two
- 420 Burkholderia and an Alcaligenes species to Ralstonia gen. Nov.: Proposal of Ralstonia
- 421 pickettii (Ralston, Palleroni and Doudoroff 1973) comb. Nov., Ralstonia solanacearum
- 422 (Smith 1896) comb. Nov. and Ralstonia eutropha (Davis 1969) comb. Nov. Microbiol
- 423 Immunol, 39 (1995) 897-904.
- 424 [5] S. Eden-Green, Banana Blood Disease, INIBAP Musa Disease Fact Sheet No.3,
- 425 (1994).
- 426 [6] E. Gäumann, Onderzoekingen over de bloedziekte der bananen op Celebes I,
- 427 Mededelingen van het Instituut voor Plantenziekten, 50 (1921) 47.
- 428 [7] M. Vaneechoutte, P. Kampfer, T. De Baere, E. Falsen, G. Verschraegen, Wautersia
- 429 gen. nov., a novel genus accommodating the phylogenetic lineage including Ralstonia
- 430 eutropha and related species, and proposal of Ralstonia [Pseudomonas] syzygii (Roberts 431 et al. 1990) comb. nov, Int J Syst Evol Microbiol, 54 (2004) 317-327.
- 432 [8] Z. Li, S. Wu, X. Bai, Y. Liu, J. Lu, Y. Liu, B. Xiao, X. Lu, L. Fan, Genome sequence 433 of the tobacco bacterial wilt pathogen Ralstonia solanacearum, J Bacteriol, 193 (2011) 434 6088-6089.
- 435 [9] J. Chun, F.A. Rainey, Integrating genomics into the taxonomy and systematics of the 436 Bacteria and Archaea, Int J Syst Evol Microbiol, 64 (2014) 316-324.
- 437 [10] M. Richter, R. Rossello-Mora, Shifting the genomic gold standard for the
- 438 prokaryotic species definition, Proc Natl Acad Sci U S A, 106 (2009) 19126-19131.
- 439 [11] G. Cellier, P. Prior, Deciphering phenotypic diversity of Ralstonia solanacearum
- 440 strains pathogenic to potato, Phytopathology, 100 (2010) 1250-1261.
- 441 [12] A. Guidot, P. Prior, J. Schoenfeld, S. Carrere, S. Genin, C. Boucher, Genomic
- 442 structure and phylogeny of the plant pathogen *Ralstonia solanacearum* inferred from 443 gene distribution analysis, J Bacteriol, 189 (2007) 377-387.
- 444 [13] M. Fegan, P. Prior, How complex is the "Ralstonia solanacearum species complex",
- 445 in: C. Allen, P. Prior, A.C. Hayward (Eds.) Bacterial wilt disease and the Ralstonia
- 446 solanacearum species complex, APS Press, St Paul, MN, 2005, pp. 449-461.
- 447 [14] P. Prior, M. Fegan, Recent developments in the phylogeny and classification of
- 448 Ralstonia solanacearum, Acta Horticulturae, 695 (2005) 127-136.
- 449 [15] J.A. Castillo, J.T. Greenberg, Evolutionary dynamics of *Ralstonia solanacearum*,
- 450 Appl Environ Microbiol, 73 (2007) 1225-1238.
- 451 [16] A. N'Guessan C, S. Brisse, A.C. Le Roux-Nio, S. Poussier, D. Kone, E. Wicker,
- 452 Development of variable number of tandem repeats typing schemes for Ralstonia
- 453 solanacearum, the agent of bacterial wilt, banana Moko disease and potato brown rot.
- 454 Journal of Microbiological Methods, 92 (2013) 366-374.

- 455 [17] D.W. Gabriel, C. Allen, M. Schell, T.P. Denny, J.T. Greenberg, Y.P. Duan, Z.
- 456 Flores-Cruz, Q. Huang, J.M. Clifford, G. Presting, E.T. Gonzalez, J. Reddy, J.
- 457 Elphinstone, J. Swanson, J. Yao, V. Mulholland, L. Liu, W. Farmerie, M. Patnaikuni, B.
- 458 Balogh, D. Norman, A. Alvarez, J.A. Castillo, J. Jones, G. Saddler, T. Walunas, A.
- 459 Zhukov, N. Mikhailova, Identification of open reading frames unique to a select agent:
- 460 Ralstonia solanacearum race 3 biovar 2, Mol Plant Microbe Interact, 19 (2006) 69-79.
- 461 [18] B. Remenant, J.C. de Cambiaire, G. Cellier, J.M. Jacobs, S. Mangenot, V. Barbe, A.
- 462 Lajus, D. Vallenet, C. Medigue, M. Fegan, C. Allen, P. Prior, *Ralstonia syzygii*, the
- 463 Blood Disease Bacterium and some Asian *R. solanacearum* strains form a single genomic
- 464 species despite divergent lifestyles, PLoS One, 6 (2011) e24356.
- 465 [19] M. Salanoubat, S. Genin, F. Artiguenave, J. Gouzy, S. Mangenot, M. Arlat, A.
- 466 Billault, P. Brottier, J.C. Camus, L. Cattolico, M. Chandler, N. Choisne, C. Claudel-
- 467 Renard, S. Cunnac, N. Demange, C. Gaspin, M. Lavie, A. Moisan, C. Robert, W. Saurin,
- 468 T. Schiex, P. Siguier, P. Thebault, M. Whalen, P. Wincker, M. Levy, J. Weissenbach,
- 469 C.A. Boucher, Genome sequence of the plant pathogen *Ralstonia solanacearum*, Nature,
- 470 415 (2002) 497-502.
- 471 [20] I. Safni, I. Cleenwerck, P. De Vos, M. Fegan, L. Sly, U. Kappler, Polyphasic
- 472 taxonomic revision of the Ralstonia solanacearum species complex: proposal to emend
- 473 the descriptions of *Ralstonia solanacearum* and *Ralstonia syzygii* and reclassify current *R*.
- 474 syzygii strains as Ralstonia syzygii subsp. syzygii subsp. nov., R. solanacearum phylotype
- 475 IV strains as *Ralstonia syzygii* subsp. *indonesiensis* subsp. nov., banana blood disease
- 476 bacterium strains as *Ralstonia syzygii* subsp. *celebesensis* subsp. nov. and *R*.
- *solanacearum* phylotype I and III strains as *Ralstonia pseudosolanacearum* sp. nov, Int J
 Syst Evol Microbiol, 64 (2014) 3087-3103.
- 479 [21] K.T. Konstantinidis, J.M. Tiedje, Genomic insights that advance the species
- 480 definition for prokaryotes, Proc Natl Acad Sci U S A, 102 (2005) 2567-2572.
- 481 [22] M. Deloger, M. El Karoui, M.A. Petit, A genomic distance based on MUM indicates
- discontinuity between most bacterial species and genera, J Bacteriol, 191 (2009) 91-99.
- 483 [23] S. Kurtz, A. Phillippy, A.L. Delcher, M. Smoot, M. Shumway, C. Antonescu, S.L.
- 484 Salzberg, Versatile and open software for comparing large genomes, Genome Biol, 5485 (2004) R12.
- 486 [24] J.P. Meier-Kolthoff, A.F. Auch, H.P. Klenk, M. Goker, Genome sequence-based
- 487 species delimitation with confidence intervals and improved distance functions, BMC
- 488 Bioinformatics, 14 (2013) 60.
- 489 [25] D.H. Huson, D. Bryant, Application of phylogenetic networks in evolutionary
 490 studies, Mol Biol Evol, 23 (2006) 254-267.
- 491 [26] A.C. Hayward, H.M. El-Nashaar, U. Nydegger, L. De Lindo, Variation in nitrate
- 492 metabolism in biovars of *Pseudomonas solanacearum*, Journal of Applied Bacteriology,
 493 69 (1990) 269-280.
- 494 [27] M. Van den Mooter, M. Steenackers, C. Maertens, F. Gossele, P. de Vos, J. Swings,
- 495 K. Kersters, J. de Ley, Differentiation between *Xanthomonas campestris* pv. graminis
- 496 (ISPP List 1980), pv. phleipratensis (ISPP List 1980) emend., pv. poae Egli and Schmidt
- 497 1982 and pv. *arrhenatheri* Egli and Schmidt 1982, by Numerical Analysis of Phenotypic
- 498 Features and Protein Gel Electrophoregrams, J Phytopathol, 118: 135–156 (1987).

- 499 [28] B. Dalsing, A. Truchon, E. Gonzalez-Orta, A. Milling, C. Allen, Ralstonia
- *solanacearum* uses inorganic nitrogen metabolism for virulence, ATP production, and detoxification in the oxygen-limited host xylem environment, mBio, (2015).
- 502 [29] W.G. Zumft, Cell biology and molecular basis of denitrification, Microbiol Mol Biol
- 503 Rev, 61 (1997) 533-616.
- 504 [30] C. Camacho, G. Coulouris, V. Avagyan, N. Ma, J. Papadopoulos, K. Bealer, T.L.
- 505 Madden, BLAST+: architecture and applications, BMC Bioinformatics, 10 (2009) 421.
- 506 [31] D. Charif, J.R. Lobry, SeqinR 1.0-2: a contributed package to the R project for
- 507 statistical computing devoted to biological sequences retrieval and analysis., in:
- 508 U.B.a.M.P.a.H.E.R.a.M. Vendruscolo (Ed.) Structural approaches to sequence evolution:
- 509 Molecules, networks, populations, Springer Verlag, 2007, pp. 207-232.
- 510 [32] R.C. Edgar, MUSCLE: multiple sequence alignment with high accuracy and high 511 throughput, Nucleic Acids Res, 32 (2004) 1792-1797.
- 512 [33] R. Cramm, A. Busch, K. Strube, NO-dependent transcriptional activation of gene
- 513 expression in *Ralstonia eutropha* H16, Biochem Soc Trans, 34 (2006) 182-184.
- [34] R. Rossello-Mora, R. Amann, The species concept for prokaryotes, FEMS Microbiol
 Rev, 25 (2001) 39-67.
- 516 [35] J.M. Janda, S.L. Abbott, 16S rRNA gene sequencing for bacterial identification in
- the diagnostic laboratory: pluses, perils, and pitfalls, J Clin Microbiol, 45 (2007) 2761-2764.
- 519 [36] M. Achtman, M. Wagner, Microbial diversity and the genetic nature of microbial 520 species, Nat Rev Microbiol, 6 (2008) 431-440.
- 521 [37] A.F. Auch, M. von Jan, H.P. Klenk, M. Goker, Digital DNA-DNA hybridization for
- microbial species delineation by means of genome-to-genome sequence comparison,
 Stand Genomic Sci, 2 (2010) 117-134.
- 524 [38] R. Rossello-Mora, Updating prokaryotic taxonomy, J Bacteriol, 187 (2005) 6255-525 6257.
- 526 [39] J. Goris, K.T. Konstantinidis, J.A. Klappenbach, T. Coenye, P. Vandamme, J.M.
- 527 Tiedje, DNA-DNA hybridization values and their relationship to whole-genome sequence 528 similarities, Int J Syst Evol Microbiol, 57 (2007) 81-91.
- 529 [40] B.J. Haley, C.J. Grim, N.A. Hasan, S.Y. Choi, J. Chun, T.S. Brettin, D.C. Bruce, J.F.
- 530 Challacombe, J.C. Detter, C.S. Han, A. Huq, R.R. Colwell, Comparative genomic
- analysis reveals evidence of two novel *Vibrio* species closely related to *V. cholerae*,
- 532 BMC Microbiol, 10 (2010) 154.
- 533 [41] M. Scortichini, S. Marcelletti, P. Ferrante, G. Firrao, A Genomic redefinition of 534 *Pseudomonas avellanae* species, PLoS One, 8 (2013) e75794.
- 535 [42] M. Kim, H.S. Oh, S.C. Park, J. Chun, Towards a taxonomic coherence between
- average nucleotide identity and 16S rRNA gene sequence similarity for species
- 64 (2014) 537 demarcation of prokaryotes, Int J Syst Evol Microbiol, 64 (2014) 346-351.
- 538 [43] K.T. Konstantinidis, A. Ramette, J.M. Tiedje, The bacterial species definition in the
- 539 genomic era, Philos Trans R Soc Lond B Biol Sci, 361 (2006) 1929-1940.
- 540 [44] S.R. Henz, D.H. Huson, A.F. Auch, K. Nieselt-Struwe, S.C. Schuster, Whole-
- 541 genome prokaryotic phylogeny, Bioinformatics, 21 (2005) 2329-2335.
- 542 [45] R. Alm, P. Johansson, K. Hjerno, C. Emanuelsson, M. Ringner, J. Hakkinen,
- 543 Detection and identification of protein isoforms using cluster analysis of MALDI-MS
- 544 mass spectra, J Proteome Res, 5 (2006) 785-792.

- 545 [46] F. Ronquist, J.P. Huelsenbeck, MrBayes 3: Bayesian phylogenetic inference under
- 546 mixed models, Bioinformatics, 19 (2003) 1572-1574.
- 547 [47] K. Böhme, I.C. Fernandez-No, J. Barros-Velazquez, J. Gallardo, B. Cañas, P. Calo-
- 548 Mata, Comparative analysis of protein extraction methods for the identification of
- seafood-borne pathogenic and spoilage bacteria by MALDI-TOF mass spectrometry.,
- 550 Anal. Methods, 2 (2010) 1941–1947.
- [48] N. Degand, E. Carbonnelle, B. Dauphin, J.L. Beretti, M. Le Bourgeois, I. Sermet-
- 552 Gaudelus, C. Segonds, P. Berche, X. Nassif, A. Ferroni, Matrix-assisted laser desorption
- 553 ionization-time of flight mass spectrometry for identification of nonfermenting gram-
- negative bacilli isolated from cystic fibrosis patients, J Clin Microbiol, 46 (2008) 3361-3367.
- 556 [49] P.R. Murray, Matrix-assisted laser desorption ionization time-of-flight mass
- spectrometry: usefulness for taxonomy and epidemiology, Clin Microbiol Infect, 16(2010) 1626-1630.
- 559 [50] H.J. Ng, H.K. Webb, R.J. Crawford, F. Malherbe, H. Butt, R. Knight, V.V.
- 560 Mikhailov, E.P. Ivanova, Updating the taxonomic toolbox: classification of Alteromonas
- 561 spp. using multilocus phylogenetic analysis and MALDI-TOF mass spectrometry,
- 562 Antonie Van Leeuwenhoek, 103 (2013) 265-275.
- 563 [51] T.R. Sandrin, J.E. Goldstein, S. Schumaker, MALDI TOF MS profiling of bacteria
- at the strain level: a review, Mass Spectrom Rev, 32 (2013) 188-217.
- 565 [52] B. Remenant, B. Coupat-Goutaland, A. Guidot, G. Cellier, E. Wicker, C. Allen, M.
- 566 Fegan, O. Pruvost, M. Elbaz, A. Calteau, G. Salvignol, D. Mornico, S. Mangenot, V.
- 567 Barbe, C. Medigue, P. Prior, Genomes of three tomato pathogens within the *Ralstonia*
- 568 *solanacearum* species complex reveal significant evolutionary divergence, BMC
- 569 Genomics, 11 (2010) 379.
- 570

571

572

573 Appendices

Strain	PhySeq.	Isolated from	Geographic origin Acc. #	
GMI1000	Ι	Tomato	Guyana NC_003295 NC_00329	
FQY_4	Ι	Soil	China CP004012 CP004	
Y45	Ι	Tobacco	China	AFWL00000000
IPO1609	IIB-1	Potato	Netherlands	CU914168, CU914166
UW551	IIB-1	Geranium	Kenya	AAKL00000000
UW349	IIB-1	Potato	Brazil JQOI0000000.	
UW365	IIB-1	Potato	China JQSI0000000.	
UW491	IIB-1	Potato	Colombia	JQSH0000000.1
RS2	IIB-1	Potato	N/D	EMBL: PRJEB8309
CFBP3858	IIB-1	Potato	Netherlands	EMBL: PRJEB8309
MolK2	IIB-3	Banana	Philippines	CAHW01000040
CFBP1416	IIB-3	Plantain	Costa Rica	EMBL: PRJEB7434
CIP417	IIB-3	Banana	Philippines	EMBL: PRJEB7427
UW179	IIB-4	Banana	Colombia	EMBL: PRJEB7426
UW163	IIB-4	Plantain	Peru	EMBL: PRJEB7430
CFBP6783	IIB-4	Heliconia	French West Indies	EMBL: PRJEB7432
Po82	IIB-4	Potato	Mexico	CP002819 CP002820
IBSBF1503	IIB-4	Cucumber	Brazil EMBL: PRJEB74.	
CFBP7014	IIB-59	Anthurium	Trinidad	EMBL: PRJEB8309
CFBP2957	IIA-36	Tomato	French West Indies	EMBL: FP885897 EMBL: FP885907
$\mathbf{K}60^{\mathrm{T}}$	IIA-7	Tomato	United States	EMBL: CAGT01000001
Grenada 9-1	IIA-6	Banana	Grenada EMBL: PRJEB7428	
UW181	IIA-6	Plantain	Venezuela EMBL: PRJEB8309	
B50	IIA-24	Banana	Brazil EMBL: PRJEB7421	
IBSBF1900	IIA-24	Banana	Brazil	EMBL: PRJEB8309
CMR15	III	Tomato	Cameroon	EMBL: FP885895 EMBL: FP885896
PSI07	IV	Tomato	Indonesia	EMBL: FP885906 EMBL: FP885891
BDB R229	IV	Banana	Indonesia EMBL: FR854059 to FR85408	
R. syzygii R24	IV	Clove	Indonesia EMBL: FR854086 to FR854	

Table 1. *Ralstonia* spp. strains used in whole-genome analyses.

- Figure 1. A. Growth and production of nitrogen gas under anaerobic condition. Values
 represent the ratio of O.D.₆₀₀ readings following 72 hours of anaerobic incubation in
 VDM plus 30 mM NO₃⁻ vs. without added NO₃⁻. A value above 1 indicates that in the
- presence of NO_3^- a strain reached higher optical densities than in the absence of NO_3^- , indicating NO_3^- respiration enhanced growth. A value above the arbitrary threshold of 2
- 582 meets our cut-off for biological significance. Strain names in green and green '+' s
- indicate N₂ gas was produced within 96 hours of anaerobic inoculation in VDM + 30 mM
- NO_3 . Production of N₂ indicates that the strain completed the full denitrification pathway
- as indicated by production of visible N_2 gas bubbles. Bars indicate standard error. Data
- represent the means of 4-6 biological replicates. **B.** Summary of the presence/absence of
- denitrification genes. Black/gray cells indicate the presence of a gene in all the sequencedstrains of this group and white cells indicate its absence.
- Figure 2. Phylogenetic network derived from the distance matrices generated with ANI,
 MUMi and GGDC methods using the SplitsTree4 software. The orange, blue and green
 cells represent strains clustered into species using the criteria specific to the ANI, MUMi
- and GGDC methods, respectively.
- 593 **Figure 3.** Majority-rule consensus tree based on the presence/absence of a consensus
- 594 MALDI-TOF peak list obtained using the MrBayes software. The probability values are 595 indicated along the main branches. Red colored strains indicate the sequenced strains.
- 596 Black lines delineate strain clusters.
- 597 Supplemental Table 1. Genomes used in the present study. Pairwise comparisons of 28
 598 sequenced genomes from the *R. solanacearum* species complex using the ANI, MUMi
 599 and GGDC methods. The orange, blue and green cells represent strains clustered into
 600 species using the criteria specific to each method.
- 601 **Supplemental Table 2.** Bacterial strains used for proteomic analysis. Phylotype and 602 sequevar classifications for the strains in the *R. solanacearum* species complex were
- 603 determined as previously described [13]. The sequenced strains are highlighted in green.
- 604

Conclusion

Ce travail soutient donc fortement la révision taxonomique du complexe d'espèces et complémente les méthodes historiques utilisées par Safni *et al.* en s'appuyant sur des techniques plus modernes, tirant notamment partie de la disponibilité croissante des séquences génomiques de *R. solanacearum*.

Les conclusions de cette étude reposent principalement sur les analyses de distances génomiques. Les résultats ont démontré l'élévation de *R. solanacearum* en plusieurs espèces à l'aide de valeurs seuils corrélant avec la DDH, en définitive. Bien que compatibles, les délimitations proposées par chaque algorithme sont néanmoins différentes (**Figure 19**). De manière intéressante, la technique la plus récente se montre la plus discriminante tandis que la plus ancienne est très conservatrice. Effectivement, GGDC classe, par exemple, le phylotype I et III comme des espèces distinctes alors qu'ANI les regroupe en une seule. Les données phénotypiques disponibles dans la littérature ainsi que celles produites par Safni *et al.* sont en faveur d'un schéma à trois espèces tel que celui proposé par ANI. Dans le cas de *R. solanacearum*, ANI semble donc être la distance génomique reflétant le mieux la réelle diversité biologique du complexe d'espèce. Les résultats fournis par GGDC n'en sont pas moins valides et illustrent quant à eux la forte diversité génétique de *R. solanacearum*, et plus généralement la complexité de la notion d'espèce chez les procaryotes.

La révision taxonomique chez *R. solanacearum* présente un intérêt multidisciplinaire. En agronomie, dans le domaine de la sélection variétale, une séparation distincte des espèces permettra de mieux définir le spectre de résistance des cultivars commerciaux. En effet, la plupart des obtentions variétales pour une résistance forte vis-à-vis de *R. solanacearum* n'expriment quasiment jamais cette propriété de résistance en réponse à l'ensemble des souches dans chacun des phylotypes. Par exemple, des variétés données comme résistantes au flétrissement bactérien se révèlent à l'usage être parfaitement sensibles à des souches endémiques autres que celles ayant contribuées à sélectionner pour ce caractère.



Figure 19 – Matrices de distances génomiques produites avec les algorithmes ANI, MUMi et GGDC. Les espèces délimitées à l'aide du seuil équivalent a 70% DDH sont représentées par des plages colorées.

De la même manière, cette résistance peut être contournée lors de l'introduction de matériel végétal contaminé par un autre phylotype. Ce flou concernant l'étendue de la résistance des variétés commerciales peut favoriser la survenue d'épidémie et est en partie due à la méconnaissance de la diversité génétique des souches de *R. solanacearum* dans les régions pour lesquelles ces variétés sont développées.

La classification proposée permettra également une clarification dans les textes légiférant sur les organismes de quarantaines. En dehors de l'écotype Brown rot, peu de distinction est faite au plan officiel entre les différents sous-groupes de *R. solanacearum*. Une division en plusieurs espèces facilitera également le suivi épidémiologique des souches et contribuera à éclaircir les routes d'invasion, les sources d'introduction et la dynamique de leur circulation.

Chapitre 3 – Génomique comparative chez les écotypes du phylotype II

Les mécanismes déterminants la gamme d'hôte ont toujours été au centre des questions de recherche dans le domaine de la pathologie végétale en général, et chez l'agent du flétrissement bactérien en particulier. De part sa capacité à infecter un nombre important d'espèces végétales par rapport aux phytopathogènes bactériens, fongiques ou viraux, *R. solanacearum* constitue un modèle expérimental de choix pour étudier l'adaptation à l'hôte. Ces dernières années, la communauté a cependant rencontré plusieurs barrières freinant la progression des connaissances sur le spectre d'hôte, malgré la disponibilité de collections de souches renfermant une importante diversité aussi bien génétique, phénotypique ou géographique. Les mécanismes fondamentaux du flétrissement bactérien ont été extensivement caractérisés au cours des avancées en biologie moléculaire, mais de nombreux points restent encore à approfondir. Le cycle infectieux chez R. solanacearum est présenté en deux étapes, une étape précoce et une autre tardive, étapes pendant lesquelles différents facteurs de virulences sont exprimés, la transition entre ces étapes étant déterminée par des systèmes de 'quorum sensing'. Des études récentes sur l'expression des régulateurs centraux de la virulence ont cependant remis en question le schéma précédemment établi (Jacobs et al., 2012 ; Zuluaga et al., 2013). La découverte des effecteurs de type III et du système de sécrétion de type III chez de nombreux agents phytopathogènes a permis d'identifier diverses stratégies impliquées dans la pathogénicité, la subversion des défenses de la plante et la modification du spectre d'hôte. Le répertoire d'effecteur chez *R. solanacearum* est en moyenne plus important que chez d'autres espèces bactériennes et un faible nombre d'effecteurs est conservé chez toutes les souches (Figure 20). De plus, les effecteurs possèdent souvent des effets redondants ou cumulatifs compliquant alors la caractérisation du rôle précis d'un effecteur unique (Genin and Denny, 2012).



Figure 20 – Matrice illustrant la présence/absence des facteurs de virulence au sein du RSSC réalisée à partir des génomes séquencés. Chaque ligne correspond à un génome et chaque colonne correspond à un facteur de virulence (la matrice détaillée est disponible dans données supplémentaires de la publication associée a ce chapitre).

Bien qu'il soit avéré que *R. solanacearum* possède une vaste gamme d'hôte à l'échelle de l'espèce, le potentiel infectieux de souches individuelles a rarement été évalué chez plus de trois ou quatre hôtes simultanément. Les travaux de Lebeau *et al.* (2011) ont démontré que les différents niveaux de virulence et d'agressivité entre souches, combinés à divers degrés de résistances de l'hôte, peuvent compliquer la désignation d'une souche donnée comme pathogène sur tel ou tel hôte (Lebeau et al., 2011). Au contraire, les travaux de Cellier *et al.* (2010) ont contribué à prouver la forte association entre des groupes génétiques du complexe d'espèces et certains hôtes (Cellier and Prior, 2010). Sur les bases de ces études, plusieurs souches représentatives de ces groupes génétiques ont été séquencées avec des technologies de 2^{nde} génération. Les groupes concernés sont :

- i. Brown rot : souches IIB-1 adaptées à la pommes de terre en climat tempéré. Ce groupe est particulièrement étudié par des équipes Nord Américaines compte tenu de son statut d'agent de quarantaine et d'agent potentiel de bioterrorisme. Un génome complet préexistait (UW551) et un génome draft nous a été fourni par Boris Vinatzer.
- Moko : groupe polyphylétique composé des 4 lignées IIB-3, IIB-4, IIA-6 et IIA-24 pathogènes du bananier. Un génome draft d'une souche IIB-3 (Molk2) était préexistant et des génomes drafts pour les trois autres lignées ont été produit dans cette étude.
- iii. NPB (Non Pathogène du Bananier) : groupe phylogénétiquement proche de la lignée Moko IIB-4 sans aucun pouvoir pathogène sur le bananier, mais variant particulièrement virulent sur certaines Cucurbitacées et Solanacées. Aucune souche de ce groupe n'avait été séquencée auparavant.

La production de génomes de souches provenant de groupes et de lignées encore non séquencés représentait donc une étape indispensable pour étudier l'adaptation à l'hôte. En effet, les groupes Brown rot et NPB sont tout deux phylogénétiquement proches de certaines lignées Moko. Notre hypothèse de départ stipulait que la proximité génétique entre ces différents groupes de souches combinées aux différences majeures entre leur spectre d'hôtes nous permettrait d'identifier des gènes directement impliqués dans la spécificité d'hôte, en comparant leurs génomes *in silico*. La difficulté principale rencontrée lors cette étude a été l'analyse des génomes drafts. Les méthodes de séquençage de 2^{nde} génération fournissent rapidement et à faible coût une séquence représentant la quasi-intégralité du génome d'une souche avec un très faible taux d'erreur, mais cette dernière demeure sous la forme de plusieurs contigs distincts et ne permet pas, par exemple, de distinguer les deux réplicons (chromosome et mégaplasmide) dans le cas de *R. solanacearum*. La séparation en contigs signifie également que certains gènes peuvent être incomplets car localisés en bordure de ces contigs.

L'ENSEMBLE DE CES TRAVAUX DE GENOMIQUE COMPARATIVE ONT FAIT L'OBJET D'UNE PUBLICATION ACCEPTEE LE 14 FEVRIER 2015 DANS LA REVUE INTERNATIONALE BMC GENOMICS [IF 4,04] : « COMPARATIVE GENOMIC ANALYSIS OF *RALSTONIA SOLANACEARUM* REVEALS CANDIDATE GENES FOR HOST SPECIFICITY».

RESEARCH ARTICLE



Open Access

Comparative genomic analysis of *Ralstonia solanacearum* reveals candidate genes for host specificity

Florent Ailloud^{1,3}, Tiffany Lowe², Gilles Cellier³, David Roche⁴, Caitilyn Allen² and Philippe Prior^{1,5*}

Abstract

Background: *Ralstonia solanacearum* is a vascular soil-borne plant pathogen with an unusually broad host range. This economically destructive and globally distributed bacterium has thousands of distinct lineages within a heterogeneous and taxonomically disputed species complex. Some lineages include highly host-adapted strains (ecotypes), such as the banana Moko disease-causing strains, the cold-tolerant potato brown rot strains (also known as R3bv2) and the recently emerged Not Pathogenic to Banana (NPB) strains.

Results: These distinct ecotypes offer a robust model to study host adaptation and the emergence of ecotypes because the polyphyletic Moko strains include lineages that are phylogenetically close to the monophyletic brown rot and NPB strains. Draft genomes of eight new strains belonging to these three model ecotypes were produced to complement the eleven publicly available *R. solanacearum* genomes. Using a suite of bioinformatics methods, we searched for genetic and evolutionary features that distinguish ecotypes and propose specific hypotheses concerning mechanisms of host adaptation in the *R. solanacearum* species complex. Genome-wide, few differences were identified, but gene loss events, non-synonymous polymorphisms, and horizontal gene transfer were identified among type III effectors and were associated with host range differences.

Conclusions: This extensive comparative genomics analysis uncovered relatively few divergent features among closely related strains with contrasting biological characteristics; however, several virulence factors were associated with the emergence of Moko, NPB and brown rot and could explain host adaptation.

Keywords: Ralstonia solanacearum, Comparative genomics, Host adaptation

Background

Although many plant pathogens are narrowly adapted to one or a few related plant hosts, *Ralstonia solanacearum* has an unusually broad host range that includes monocotyledonous and dicotyledonous hosts [1]. *R. solanacearum* infects plant vascular systems, causing diverse bacterial wilt diseases. Its extensive host range, together with a wide geographic distribution, makes it one of the world's most destructive crop pathogens [2]. *R. solanacearum* has many distinct lineages within a heterogeneous and taxonomically disputed species complex. Extensive phylogenetic analysis demonstrates that the species complex contains four

* Correspondence: philippe.prior@cirad.fr

¹CIRAD, UMR PVBMT, F-97410 Saint-Pierre, La Réunion, France

phylotypes that correspond to geographic origin; phylotype I strains originated in Asia, phylotype II strains came from the Americas, phylotype III strains originated in Africa, and phylotype IV strains are from the Indonesian archipelago [3]. Within each phylotype, strains can be further subclassified into sequevars based on the similarity of a 750-bp fragment of the endoglucases (egl) gene [3]. R. solanacearum strains share a conserved core genome that is presumably essential for their common biology: colonizing plant xylem vessels and causing wilt symptoms [4,5]. However, the group's pan-genome contains over 16,000 coding sequences (CDSs), and individual strains in the species complex vary enormously with respect to both epidemiology and host range. For example, the R. solanacearum species complex includes strains adapted to eucalyptus, mulberry, clove, ginger, banana, peanut, and solanaceous plants [1].



© 2015 Ailloud et al; licensee BioMed Central. This is an Open Access article distributed under the terms of the Creative Commons Attribution License (http://creativecommons.org/licenses/by/4.0), which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly credited. The Creative Commons Public Domain Dedication waiver (http://creativecommons.org/publicdomain/zero/1.0/) applies to the data made available in this article, unless otherwise stated.

⁵Département de Santé des Plantes et Environnement, (SPE) Inra, Paris, France

Full list of author information is available at the end of the article

Functional genetic analyses have identified many of R. solanacearum's broadly conserved common virulence mechanisms [6,7]. However, the molecular processes that are responsible for strains' adaptation to particular hosts are not well understood. A few studies have identified specific type III effectors and metabolic traits associated with host range [8-11]. However, these findings were validated in only a few model strains using plants that fail to represent the large diversity of the species complex's host range. Previous comparative analyses did not identify strong host specificity factors but were based on strains with a limited genetic diversity or failed to consider the entire host spectrum of each strain [12,13]. A recent study that characterized the bacterium's genetic and phenotypic heterogeneity allowed us to select new model strains and to further explore the underlying mechanisms that determine host range [14].

Microarray and multilocus sequence typing (MLST) analyses and surveys of biological diversity demonstrated the existence of several clonal lineages adapted to specific host plants inside the American phylotype II group of the R. solanacearum species complex [12,14-16]. Lineages consisting of strains with similar host ranges are grouped into ecotypes, as they represent genetically distinct populations adapted to particular ecological niches within the R. solanacearum species complex (RSSC). These lineages include the banana Moko disease-causing strains, the cold-tolerant potato brown rot strains (historically and for regulatory purposes known as Race 3, biovar 2 or R3bv2) and the Not Pathogenic to Banana (NPB) strains, a recently emerged group that does not wilt banana despite its phylogenetic location in sequevar 4; all other sequevar 4 strains cause Moko disease. We hypothesized that host range determinants could be identified by comparing the genomes of closely related strains that have highly divergent host ranges. The polyphyletic nature of the Moko ecotype and the unexpectedly close relationship of some Moko lineages to the monophyletic brown rot and NPB ecotypes make these highly adapted strains a robust model for the study of host adaptation.

In this study, we sequenced a representative group of strains from each of these ecotypes and analyzed their genomes using multiple comparative genomics methods. Genomes were compared using phyletic profiling to determine ecotype-specific gene content. We identified genetic variations associated with NPB and brown rot strains emergence. To gain a better understanding of the polyphyly of Moko strains, horizontal gene transfers (HGTs) were also investigated using an explicit phylogenetic method. Each of these analyses has proven successful in several other plant pathogenic bacteria, including *Pseudomonas syringae* [17] and *Xanthomonas* sp. [18,19], and has provided evidence that specific gene content, genetic variations and HGT can explain host adaptation.

These comparative genomic analyses identified several virulence factors associated with NPB and brown rot strain emergence, along with Moko strain polyphyly. However, there were surprisingly few differences in lineage-specific gene content that could explain the host adaptation of the various lineages despite the high plasticity of the pan-genome.

Results

Host-adapted strains from phylotype II offer a model to study host adaptation

The general features of the R. solanacearum genomes analyzed in this study are presented in Table 1. We selected eight phylotype II strains for sequencing based on their sequevar classifications and on phenotypic data that indicated host adaptation. Eleven additional RSSC genomes were obtained from public databases. The three brown rot strains form a monophyletic group adapted to temperate climate; these sequevar 1 strains are typically isolated from potato in the highland tropics. The Moko disease strains form a polyphyletic group adapted to banana and are represented in this analysis by seven strains from sequevars 3, 4, 6 and 24, all isolated from plants in the genus Musa. The NPB strains form an emerging monophyletic group that appears to have diverged recently from Musa-infecting strains in sequevar 4. This group is represented by two strains, one isolated from Cucumis and one from Heliconia [15].

We determined draft sequences of a total of eight new phylotype II draft genomes. The resulting whole-genome data were used to confirm the phylogenetic relationships previously inferred from the phylotype-sequevar classification. We used Maximum Unique Matches index (MUMi) genomic distances [20] to generate a new, more complete phylogenetic tree of the R. solanacearum species complex (Figure 1). The tree exhibits a similar topology as the previously inferred phylogeny, which was based on microarray or MLST data. Although the strains in phylotype II are closely related to the relative context of the species complex, the Moko group is clearly polyphyletic and includes four distinct lineages that correspond to sequevars 3, 4, 6 and 24. Interestingly, Moko sequevar 3 is closely related to the monophyletic potato brown rot lineage, and Moko sequevar 4 is even more closely related to the monophyletic NPB lineage.

To confirm the host-adapted nature of the selected phylotype II strains, we initially conducted pathogenicity assays under tropical conditions using tomato, potato, banana (*Musa*), melon (*Cucumis*) and *Anthurium* as representative hosts. The pathogenicity profiles obtained from these assays clearly demonstrate the host adaptation of each group (Figure 2). Moko strains from sequevars 3, 4, 6 and 24 wilted banana plants, but the sequevar 4-NPB strains did not. The NPB strains were

Phylotype - sequevar	Strain	Genome length (Mb)	GC %	#Contig	#CDS	Isolated from	Geographic origin
	GMI1000	5.81	66.9%	2	5635	Tomato	Guyana
IIB-1	IPO1609	5.24	66.7%	102	5203	Potato	Netherlands
	UW551	5.22	64.8%	561	5301	Geranium	Kenya
	UW491	5.27	66.7%	222	5035	Potato	Colombia
IIB-3	MolK2	5.48	66.7%	30	5438	Banana	Philippines
	CFBP1416*	5.68	66.6%	653	5722	Plantain	Costa Rica
	CIP417*	5.47	66.8%	609	5398	Banana	Philippines
IIB-4	UW179*	5.37	66.7%	590	5354	Banana	N/A
	UW163*	5.48	66.6%	572	5467	Plantain	Peru
	Po82	5.43	66.6%	115	5019	Potato	Mexico
IIB-4 NPB	CFBP6783*	5.54	66.7%	655	5505	Heliconia	French West Indies
	IBSBF1503*	5.45	66.7%	633	5452	Cucumber	Peru
IIA-7	K60	5.33	66.7%	23	5102	Tomato	United States
IIA-6	Grenada91*	5.41	66.6%	670	5365	Banana	Grenada
IIA-24	B50*	5.49	66.4%	1088	5648	Banana	Peru
III	CMR15	5.61	65.0%	3	5149	Tomato	Cameroon
IV	PSI07	5.62	64.5%	3	5247	Tomato	Indonesia
	BDB R229	5.23	66.3%	13	5051	Banana	Indonesia
	R. syzygii R24	5.45	65.9%	2	5239	Clove	Indonesia

Table 1 General characteristics of the strains and genomes used in this study

* Genomes sequenced during this study.

the only group able to infect melon and *Anthurium* plants. Finally, Moko, NPB, and brown rot strains can all infect potato plants at warm temperatures, but only brown rot strains are highly virulent under cooler temperate conditions [14]. It is important to note that not all strains in phylotype II exhibit this degree of host adaptation. For example, and as expected from the literature, the broad host range of *R. solanacearum* type strain K60 (which also causes disease in tobacco,

eggplant, and pepper) did not extend to banana, melon or anthurium under our experimental conditions.

Genomic diversity of phylotype II and the *R. solanacearum* species complex

A total of 16,757 distinct homolog families were identified across the 19 *R. solanacearum* genomes; we consider these homologs to be the current pan-genome of the species complex. Compared with a previous genomic





analysis of eight R. solanacearum genomes [5], our results expand the pan-genome size by ~70%. The inclusion of previously unsequenced and phylogenetically distinct lineages, notably sequevars 4, 6 and 24, explains the steep increase in the pan-genome size. The 1,940 loci conserved in all strains constitute the current R. solanacearum core genome, which represents 17% of the pan-genome and 35% of an average R. solanacearum genome, which contains ~5,500 CDSs. Ecotype-specific gene content was determined by individually comparing each ecotype to every other sequenced genome. The NPB and brown rot strains each exhibited only a few unique genes specific to their phylogenetic groups: 99 and 109, respectively (Figure 3). The Moko strains are unlikely to exhibit specific genes because this polyphyletic group is composed of distant lineages. Three hypotheses can explain the emergence of a polyphyletic Moko ecotype. First, the most common recent ancestor (MRCA) of phylotype II may have been adapted to bananas. During the subsequent clonal expansion, variations in environmental selection pressures may have promoted maintenance of the ancient phenotype in certain lineages (which still cause Moko disease) and promoted its loss in others. Alternatively, because R. solanacearum is capable of natural transformation [21], pathogenicity to banana may have originated in an isolated lineage after divergence from the MRCA. Subsequently, the banana-infecting trait(s) may have spread to multiple phylotype II lineages via HGT, resulting in the current polyphyletic Moko group. A third possibility is that multiple lineages underwent convergent evolution towards the banana-infecting trait, which is consistent with the absence of ecotype-specific genes.

We selected a subset of 227 known or likely virulence factors from the pan-genome based on the literature and

manually annotated them (Additional file 1). These virulence factors have a broad range of functions during pathogenesis, including the secretion and synthesis of type III effectors (T3es), motility, chemotaxis, synthesis of exopolysaccharide (EPS), and degradation of plant cell walls. Compared with the other virulence factors, the T3e repertoire of *R. solanacearum* exhibits high plasticity. The pan-effectome of the species complex contains 113 T3es, but of those, only 14 effectors are present in every sequenced strain. These 14 effectors form the core effectome: RipG5, RipB, RipW, RipAC, RipAB, RipR,



RipE1, RipAM, RipAN, RipAY, RipAJ, RipF1, RipAI and a PopC-like effector. The core effectome represents a ~36% size decrease relative to the previously inferred core effectome based on 11 strains [13]. On average, 64 T3es were present per strain. A total of 40 T3es were common to all Moko strains, whereas 76 were common to NPB strains, and 52 were common to brown rot strains.

Due to the large pan-genome, each strain appeared to exhibit highly diverse genetic content even within the Moko, NPB and brown rot groups. This variability can be partially explained by the estimation of gene gain and loss rates along lineages. Indeed, each phylogenetic node of the species complex appears to have undergone hundreds of gain and loss events, thus creating mosaic genomes (Additional file 2). This gain and loss explains why some homolog families are shared by distant lineages but not by closer ones. Nonetheless, it is important to consider that the new genomes are in draft form and are divided into contigs. Thus, these genomes contain fragmented CDSs that can artificially increase the number of predicted gene families and introduce some bias into subsequent analysis.

Pairwise comparison of the genomic content of Moko with the NPB and brown rot strains

To overcome the problem of these mosaic genomes and to specifically target gene content associated with host adaptation, we hypothesized that the brown rot clade emerged when the IIB-1 brown rot strains diverged from the IIB-3 Moko lineage. Similarly, we hypothesized that the NPB clade emerged when the IIB-4 NPB lineage diverged from the IIB-4 Moko strains. This methodology thus focuses on the evolution of genomic content during emergence events. To test these hypotheses, we directly compared the co-occurrence patterns of genes of the IIB-1 brown rot genomes to those of the Moko genomes and the IIB-4 NPB genomes to the Moko genomes. The first step was to establish which genes were unique to the brown rot and NPB strains compared with the Moko strains. Subsequently, we determined which genes were conserved in every Moko lineage but were absent in either the NPB or brown rot strains (Additional file 3).

The NPB strains exhibited 102 unique genes missing from all Moko strains. These genes fell into three putative genomic islands. The first one encoded a type I secretion system (T1SS), including an outer membrane protein (RALP6v1_3180004), a membrane fusion protein (RALP6v1_3180005), and an ATP-binding protein (RALP6v1_ 3180006). This secretion system is located next to a transposase homolog (RALP6v1_3180003), suggesting that the genes were most likely acquired by HGT. The second genomic island contained genes related to the degradation of the plant alkaloid isoquinoline (*iorA* and *iorB*) located next to a gene encoding an AraC-type transcriptional regulator. The third genomic island contained a gene with a phosphatase 2C domain, a motif usually found in eukaryotic organisms. Phosphatase 2C can be involved in various cell functions, including the regulation of plant defense in Arabidopsis [22], and is sometimes secreted into host cells by pathogens [23]. The genomic island also contained a gene encoding a putative helixturn-helix (HTH)-type transcriptional regulator as well as transposition-related genes, suggesting that it was also acquired by HGT. Outside of these clearly defined putative genomic islands, CDSs encoding another HTH-type transcriptional regulator and a GGDEF-domain signal transduction protein were unique to the NPB genomes.

Only six genes were conserved in Moko strains but absent from NPB strains. Interestingly, this gene-set included *ripAA*, a well-characterized T3e formerly known as *avrA* [8], which was either absent or pseudogenized in NPB strains. This effector was highly conserved in Moko strains (~85% nucleotide identity) and in the species complex (present in 15 out of the 19 sequenced strains), thus suggesting that *ripAA* was lost during the emergence of NPB. Another GGDEF-domain signal transduction protein was also absent from the NPB strains.

Brown rot strains exhibited 134 conserved genes that were absent from all Moko strains. One hundred three genes coded for conserved proteins of unknown function. However, a BLAST search on NCBI's nr database revealed that several of these hypothetical proteins exhibited homologs in other genera of soil-dwelling and plant pathogenic bacteria (e.g., Xanthomonas, Pseudomonas, Cupriavidus and others). We identified a single putative functional genomic island related to iron metabolism: a FecR homolog (UW551v3_mp40033) located next to an iron transporter (UW551v3_mp40034) and a sigma 70 factor (UW551v3_mp40032). Another gene block coding for hypothetical proteins without significant BLAST hits was also located next to an AraC-type transcriptional regulator. Finally, a member of the RTX exotoxin family (UW551v4_570022) was unique to the brown rot strains.

We identified 63 genes that were conserved in Moko strains and missing from brown rot strains. A large gene block included several genes of interest: the T3e *ripAU*, a two-component system involved in the stress response of *cpxR* and *cpxA*, multiple drug efflux pumps from the Acr and RND families, and an AraC-type transcriptional regulator. Several isolated transcriptional regulators, including one each from the TetR and MarR families, were also identified.

Our analyses identified similar numbers of NPB- and brown rot-specific genes relative to Moko strains. Although NPB strains exhibited three specific genomic islands that may be related to adaptation (potentially acquired by HGT), brown rot strains exhibited more than one hundred specific genes encoding proteins of unknown function that appeared to be conserved in other bacteria. Although gene loss was globally more predominant in brown rot strains than in NPB strains, both ecotypes only lost a single distinct T3e each (*ripAU* and *ripAA*, respectively), possibly while diverging from their respective Moko lineages. These contrasting rates of gene loss between effectors relative to the rest of the genome suggest that the loss of these two effectors could have been key events in the emergence of these ecotypes.

HGT events between Moko lineages

To test the hypothesis that adaptation to banana spread through Moko lineages of phylotype II via HGT, we searched for signs of transfer between Moko lineages using the AnGST algorithm. This algorithm compares gene trees with their associated species tree and infers both HGT events and the direction of transfer by identifying conflicts between the two. We only considered genes with HGT patterns involving all four Moko lineages and directions of transfers compatible with a unique original donor. According to our hypothesis, this unique donor would be pathogenic to banana (Additional file 2). This strategy identified nine genes. Five of these genes exhibited the IIA Moko lineages MRCA as the likely donor with the IIB Moko lineages as acceptors. Of these five genes, two encode the T3es ripAD and ripG4 from the GALA family. The others encode two hypothetical proteins and a bacteriophage-related protein. Three genes exhibited the IIB-3 lineage as the donor and putatively encode a protein belonging to the beta-lactamase superfamily, the translation initiation factor *infA*, and *hrcT*, a key component of the T3SS. The only gene that apparently exhibited the IIB-4 lineage as a donor encodes a putative adenine-specific methyl-transferase.

This analysis suggests that a small minority of genes seems to have spread through every Moko lineage via a single lineage (the hypothetical original donor). Although the original donors were not fully consistent, more than half of the HGT events originally started from the IIA Moko's MRCA and affected T3es that are likely to be directly involved in pathogenesis.

Association of sequence polymorphisms with host-adaptation

Due to the phylogenetic proximity of NPB and brown rot strains to individual Moko lineages, we analyzed the diversity of their shared genomic content. We analyzed multiple alignments of protein sequences to search for nonsynonymous single-nucleotide polymorphisms (NS-SNPs) and insertions and deletions (INDELs) associated with the host-adapted groups. We will refer to these features as host-adapted polymorphisms (HAPs). More precisely, we selected polymorphisms that exhibited the same form in Moko strains but a different form in either the NPB or brown rot strains (Additional file 4). Of the 2,855 genes common to the NPB and Moko strains, 96% were polymorphic. However, only 24 genes (<1%) contained HAPs, including 16 within conserved domains in protein sequences. This result can be explained by the very low divergence of the IIB4-NPB and IIB4 Moko lineages, as only 14% of their common genes are polymorphic. Notable NS-SNPs were identified in the T3e *ripAN* and in a PadR-like transcription regulator involved in the response to phenolic compounds; notable INDELS were identified in *motB*, a flagellar motor protein involved in the response to chemotaxis signals, and *epsF*, a membrane protein involved in the secretion of EPS. NS-SNPs were also identified in two multidrug resistance proteins (MDRs) and an HTH-type transcriptional regulator.

Ninety-nine percent of the 2459 common genes present in both the brown rot and Moko strains were polymorphic. Of these, 1024 genes (42%) contained HAPs, including 742 within protein domains. Twenty T3es contained the majority of NS-SNPs, including five T3es with more than ten NS-SNPs (*ripV1, ripG6, ripC1, ripAO* and *ripAD*), three members of the GALA T3e family and *ripAB* and *ripAC*. Two regulators and subunits of the T3SS were polymorphic: *prhJ* and *hrpAFGHJ*. Several HAPs were found in genes encoding members of diverse metabolic pathways, notably the NorB and NasF enzymes of inorganic nitrogen metabolism. Finally, 22 putative transcriptional regulators of various families contained HAPs in their substrate-binding domains.

Discussion

Using comparative genomic analysis, we compared the genomes of three host-adapted groups of strains from the phylotype II of *R. solanacearum*: brown rot strains adapted to potatoes and temperate climates, Moko strains adapted to bananas, and NPB strains adapted to melon or *Anthurium*. Together, our analyses demonstrated that the potato brown rot, Moko, and NPB strains constitute phylogenetically related populations that have adapted to biologically distinct host environmental conditions. Thus, these phylotype II groups, called ecotypes, provided a good model to explore host adaptation in *R. solanacearum*. We hypothesized that comparing the genomes of these closely related but biologically distinct groups could identify specific mechanisms of host adaptation.

Overall, the species complex appeared to be very dynamic, with a large pan-genome and a limited core genome. Specifically, the *R. solanacearum* T3e repertoire was unusually large compared with those of other well-known plant pathogens such as *Pseudomonas* spp. or *Xanthomonas* spp. [24,25]. The variability of T3es suggests that there may be extensive functional redundancy between effectors. Paralog families, such as the

GALA effectors, are known to exhibit functional redundancies, and single effector mutations rarely produce a virulence defect [10]. These functional redundancies drastically reduce the analytic power of comparative genomics; therefore, more data about the specific virulence functions of individual T3es are needed to better understand the biological mechanisms underlying host adaptation. Such data are especially important considering that among the few functionally characterized T3es [26], only *ripR* (*popS*) is a member of the *R. solanacearum* core effectome.

Three competing hypotheses could explain the origin of polyphyly of the Moko strains. The first hypothesis proposes that the phylotype II MRCA was a banana pathogen and that the capacity to infect banana was subsequently lost in multiple clades after clonal expansion due to variations in environmental selection pressures. Our analyses did not identify any genes present in all Moko strains but absent in all other R. solanacearum strains. Although this observation seems to contradict our hypothesis, it does not invalidate the hypothesis but rather suggests that different parts of the set of hypothetical genes responsible for the banana virulent phenotype present in phylotype II's MRCA could have been lost in non-Moko lineages. This phenomenon would have contributed to the mosaic nature of R. solanacearum genomes and would have been facilitated by functional redundancies.

Our second hypothesis states that banana pathogenicity emerged in a single clade and spread among phylotype II strains by HGT facilitated by natural transformation. Despite the large gene pool shared by Moko strains, only nine genes exhibited HGT patterns consistent with our hypothesis. We determined that the T3e ripAD that was transferred from the common ancestor of the IIA-6/24 Moko lineages to the IIB-3/4 Moko lineages. This effector does not possess the regulatory hrp_{II} box motif but is expressed in an hrpB-dependent manner and is translocated into plant cells [27]. Moreover, although its function is not characterized in R. solanacearum, it is also a member of the *hpx8* family found in plant pathogenic Xanthomonas. Another T3e, ripG4, exhibited similar HGT patterns originating from the IIA Moko lineages. This effector is a divergent member of the GALA family that interferes with PAMP-triggered immunity in Arabidopsis and contributes to host adaptation [10].

A genomic content analysis was designed to characterize the evolution of genomic content during the emergence of the NPB and brown rot clades and to identify the specific genes that could be responsible for host range differences. Our analysis revealed that few genes separate the Moko strains from the NPB and brown rot strains despite their biologically distinct phenotypes. One of these, *ripAA*, was lost by NPB strains' MRCA during its divergence from the IIB-4 Moko lineage. This effector is recognized by tobacco, so it prevents phylotype I strain GMI1000 from infecting tobacco plants [8]. We speculate that ripAA could either be an effector that enables Moko strains to wilt banana or an avirulence factor that prevents pathogenicity in plants that are not part of the Moko strains' host range but are part of the NPB strains' host range. ripAA is a common effector in the species complex, but none of the strains with this effector are melon or Anthurium pathogens. Therefore, we propose that the loss of this effector by the NPB strains could have been a key event in this clade's host change. Similarly, ripAU was lost by the brown rot strains during the divergence from the IIB3 Moko lineage. This effector is also present in all of the other strains of the species complex, and its loss might have been necessary for brown rot strains to adapt to temperate climates. The cold tolerance of brown rot strains is strictly dependent on an interaction with the host [28], and T3es may play key roles in this interaction. Although the function of *ripAU* in *R. solanacearum* is unknown, this effector belongs to the hpx8 family. Hpx families are T3e families sharing protein sequence similarities defined by Mukaihara, and the hpx8 family shares similarities with the effector XopV, which is found in various plant pathogenic Xanthomonas [27]. However, the function of XopV in Xanthomonas is not well characterized.

A complete T1SS was acquired by NPB strains during their divergence from banana-infecting sequevar 4 Moko strains, most likely via HGT. T1SSs are ubiquitous and versatile systems often involved in the secretion of various virulence factors into the extracellular medium, such as proteases, toxins, or quorum-sensing molecules that can promote plant invasion [29]. T1SSs can also play a defensive role to counteract plant defense responses by exporting antimicrobial compounds out of the cell. Numerous genes encoding conserved proteins of unknown function were acquired by brown rot strains during their divergence from sequevar 3 Moko strains. Homologs of most of these genes are present in other soil-borne and plant pathogenic bacteria, suggesting that they may play a role in adaptation to either environmental conditions or unique hosts. Further characterization of these proteins of unknown function is required to determine if they participate in brown rot strain adaptation to temperate climate. Homologs of the transporter and the sensor of the iron-sensing fec system and a sigma70 factor were also encoded by brown rot-specific genes. The *fec* system is responsible for iron uptake and is essential in many human pathogens and a few enteric plant pathogens [30,31]. However, all R. solanacearum strains sequenced to date have the fur system, which depends on another siderophore. It is possible that this fec system has a ligand specificity that is more efficient at sequestering iron in potato tubers or at low temperatures. Functional analyses could determine if this additional iron uptake system is involved in brown rot cold

tolerance. Finally, we looked for polymorphisms (i.e., HAPs) that could affect the function of the genes shared between Moko and either NPB or brown rot strains. Polymorphisms are introduced by replication errors or intragenic recombination and can have a major impact on gene functionality. In plant pathogens, a single amino acid modification in TAL effectors can alter the host gene targeted by the effector [32]. Despite the genetic distances between Moko lineages and their proximity to the brown rot and NPB ecotypes, a high number of genes contained sites that were coincidentally fixed in the Moko strains but polymorphic in either NPB or brown rot strains, suggesting that these sites are functionally important and may be related to host adaptation.

NPB and Moko strains contained several HAPs in known virulence factors. The T3e ripAN had a single NS-SNP. Although RipAN is translocated into host cells [33], this effector's function in R. solanacearum is unknown. Homologs of ripAN have not been identified in other plant pathogenic bacteria. One HAP was also found in the gene encoding the inner membrane protein EpsF, which is predicted to be responsible for the modification and/or export of the exopolysaccharide EPS I, a major bacterial wilt virulence factor. A six-amino acid insertion was identified in the C-terminal end of the NPB *epsF* gene. The extent of cross-talk between plants and EPS is not yet entirely understood, but it is known that different EPS proteins trigger different plant defense responses and that EPS modifications play a role in biofilm formation, immune evasion and virulence in EPSproducing bacteria [34,35].

Furthermore, we also found a HAP in a transcriptional regulator containing a PadR-like domain. PadR domains modulate the expression of virulence factors, MDR efflux pumps and responses to phenolic stress [36,37]. Interestingly, HAPs were also identified in two independent MDR transporters. Because plants produce antimicrobial phenolic compounds in response to pathogens, the PadR and MDR genes might constitute a network for stress response/resistance to plant defense mechanisms adapted to NPB-specific host range. Altogether, the 24 HAPs identified may be necessary for NPB strains to adapt to the environmental conditions encountered in new hosts.

The brown rot and Moko strains exhibited hundreds of genes with HAPSs in conserved protein domains, suggesting that *R. solanacearum* metabolism and virulence may function differently in brown rot strains. Remarkably, the list of HAP sites included central virulence regulators, T3SS regulators, T3SS machinery, and 19 T3es. T3es with HAPs notably included an effector with a nuclear localization signal (*ripAB*) and several functionally redundant effectors known to affect host range (*ripG2*, *ripG3*, and *ripG6*) [10,38]. Recent transcriptomic studies

suggest that regulation of virulence factors during pathogenesis is far more complex than previous models proposed [39,40]. Given that brown rot's adaptation to cold is dependent on interactions with a host, a large reorganization of core mechanisms may be required for *R. solanacearum* to cause disease in temperate climates.

Conclusions

This extensive comparative genomics analysis identified relatively few differences in gene content between closely related *R. solanacearum* strains with contrasting biological characteristics. However, several T3e were associated with the Moko, NPB and brown rot ecotypes (Table 2). Most differences between strains involved HAPs of uncertain biological significance, although many HAPs were located in genes associated with bacterial wilt virulence. Our study did identify specific hypotheses concerning mechanisms of host adaptation in the *R. solanacearum* species complex. These hypotheses

Table 2 Candidate T3e for host specificity identified inMoko, NPB and brown rot ecotypes

Gene name	Alternative name	Characteristics
ripAU		Absent from brown rot, present in Moko
ripAA	avrA	Absent from NPB, present in Moko
ripG4	GALA4	HGT from IIA Moko to IIB Moko lineages
ripAD		HGT from IIA Moko to IIB Moko lineages; HAPs between brown rot and Moko
ripAB	рорВ	HAPs between brown rot and Moko
ripAC	рорС	HAPs between brown rot and Moko
ripAD		HAPs between brown rot and Moko
ripAE		HAPs between brown rot and Moko
ripAl		HAPs between brown rot and Moko
ripAO		HAPs between brown rot and Moko
ripAP		HAPs between brown rot and Moko
ripAY		HAPs between brown rot and Moko
ripB		HAPs between brown rot and Moko
ripC1		HAPs between brown rot and Moko
ripD	avrPphD	HAPs between brown rot and Moko
ripE2		HAPs between brown rot and Moko
ripF1		HAPs between brown rot and Moko
ripG2	GALA2	HAPs between brown rot and Moko
ripG3	GALA3	HAPs between brown rot and Moko
ripG6	GALA6	HAPs between brown rot and Moko
ripH1	HLK1	HAPs between brown rot and Moko
ripH2	HLK2	HAPs between brown rot and Moko
ripV1		HAPs between brown rot and Moko
ripW	popW	HAPs between brown rot and Moko
ripAN		HAPS between NPB and Moko
will be tested using functional genomics experiments such as gene swaps and deletions to determine whether these mechanisms play roles in host specificity. However, an important proportion of these candidate genes are related to regulatory function, suggesting that host range could evolve through changes in regulation. Small genomic differences could lead to drastically different expression profiles when the bacterium infects different hosts. Due to their unexpected overall genomic similarity and their clear-cut differences in host range, IIB-4 Moko and NPB form an elegant model for transcriptomic studies designed to identify differentially expressed genes associated with host specificity.

Methods

Genome sequencing and assembly

Total DNA was extracted using the phenol-chloroform method. Libraries were constructed using Nextera technology and sequenced on Illumina's HiSeq-2000 using a 2×50 -nt paired-end strategy. Reads were pre-processed using Trimmomatic [41]. First, adapter sequences and low-quality nucleotides occurring at 5' and 3' ends with a Phred quality score < 20 were trimmed. Second, reads shorter than half their initial lengths were discarded. The resulting reads were assembled using Velvet [42]. Manual editing of the annotations was performed for genes of interest using the MaGe web interface of the MicroScope platform [43]. The accession numbers are as follows: CFBP1416 [EMBL:PRJEB7434], CIP417 [EMBL:PRJEB7427], B50 [EMBL:PRJEB7421], Grenada 91 [EMBL:PRJEB7428], UW179 [EMBL:PRJEB7426], UW163 [EMBL:PRJEB7430], CFBP6783 [EMBL:PRJEB7432], and IBSBF1503 [EMBL:PRJEB7433]. Annotation files are provided in genbank format (Additional file 5).

Pathogenicity assays

Pathogenicity was assessed on 3-4 fully expanded leaves of tomato cv. L390 (T10) (30 plants), potato cv. Désirée (30 plants), Cavendish banana cv. 902 (8 plants), melon cv. Amish (30 plants) and the ornamental plant Anthurium cv. Fire (4 plants). Plants were placed in a full containment security level growth chamber with a 12-h photoperiod, $28 \pm 2^{\circ}C$ (day) and $24 \pm 2^{\circ}C$ (night), and 90% relative humidity. Bacterial suspensions were prepared as described in Cellier & Prior 2010. Using the soil-soak method, each plant was inoculated with 5×10^9 colony-forming units (CFU) after lightly damaging the roots with a scalpel. Strains were considered pathogenic if more than 50% of plants presented wilt symptoms within one month after inoculation. Each assay was repeated 2 times. We could not analyze the phenotype of strain Po82 because the authors of this published genome would not share their strains [44].

Exploratory virulence dataset

The list of *R. solanacearum* virulence factors analyzed in this study was based on Remenant et al. [12]. Orthology relationships were determined for each strain by BLAST and synteny data using the web-based MaGe interface. Every gene annotation was then manually validated to ensure homogeneity of the start codon positions and to detect frameshifts and pseudogenization. T3es were annotated using the IANT "Ralstonia T3E" database [13]. T3es located on contig borders were considered as present to establish the core effectome.

Species complex phylogeny

The species complex phylogeny was inferred by neighbor-joining using MUMi genomic distances [20]. MUMi values were computed from whole-genome comparisons conducted with MUMMer 3.0 [45].

Phyletic profiles

Homology relationships across all genomes analyzed in this study were inferred using the Orthologous MAtrix algorithm (OMA) [46] with the following default criteria: alignment length > 60% of the minimum gene length and alignment score > 181 in Gonnet PAM matrix units. Phyletic profiles [47] were subsequently determined using R to identify co-occurrence patterns for specific genes in a given group of strains. The specific gene content was locally blasted on the NCBI nr database to identify an eventual source organism.

Detection of gain, loss and HGT events

Amino acid sequences of each homolog family were aligned with Muscle [48], and a neighbor-joining phylogenetic tree supported by 1000 bootstrap replicates was computed with FastTree [49]. Gain, loss, and HGT events were inferred by reconciliation of the gene trees and the species complex tree topologies using the AnGST algorithm (Analyzer of Gene and Species Tree) [50]. This algorithm compares the topology of a gene tree with its associated species tree, which is generally defined as an explicit phylogenetic method within the scope of HGT detection. The algorithm identifies differences between the gene and the species trees and explains them ("reconciles") according to a set of evolutionary events, including gain, loss, duplication or horizontal transfer, inferred with a parsimony-based model. Loci with > 95% nucleotide identity were discarded to avoid false positives caused by phylogenetic trees with insufficient resolution.

Allelic variation analysis

Nucleic and protein sequences of each homolog family were aligned with Muscle [48]. The resulting alignments were trimmed on the 5' ends and then screened for host-associated amino-acid polymorphisms using R. The strain MolK2 was used as a reference to assign the position of each polymorphism in the sequence. Functional domains containing polymorphisms were identified using the CDD database from NCBI.

Availability of supporting data

The data sets supporting the results of this article are included within the article and its additional files. Sequence data are available at the EMBL nucleotide sequence database:

- CFBP1416 http://www.ebi.ac.uk/ena/data/view/ PRJEB7434
- CIP417 http://www.ebi.ac.uk/ena/data/view/ PRJEB7427
- B50 http://www.ebi.ac.uk/ena/data/view/PRJEB7421
- Grenada 91 http://www.ebi.ac.uk/ena/data/view/ PRJEB7428
- UW179 http://www.ebi.ac.uk/ena/data/view/ PRJEB7426
- UW163 http://www.ebi.ac.uk/ena/data/view/ PRJEB7430
- CFBP6783 http://www.ebi.ac.uk/ena/data/view/ PRIEB7432
- ISBSF1503 http://www.ebi.ac.uk/ena/data/view/ PRIEB7433

Additional files

Additional file 1: Subset of 227 virulence factors from the

pan-genome. These genes were manually selected and annotated. Red cells: absent gene. Orange cells: pseudogenized of frameshifted gene. Black: Fragmented genes due to sequencing gaps.

Additional file 2: Results from the analysis with the AnGST

algorithm. Gene gain and loss events in the species complex and HGT patterns between Moko lineages. Black boxes indicate that the lineage is involved in the HGT.

Additional file 3: Results of phyletic profiling. List of genes present or absent in NPB or brown rot strains when compared to Moko strains Results of BLASTp in the NCBI nr database are provided.

Additional file 4: Results from the analysis of HAPs. List of HAPs contained in genes shared by NPB or brown rot strains with Moko strains are provided. Protein domains predicted from NCBI CDD database and containing HAPs are indicated.

Additional file 5: Annotations files (.gb). Annotations are formatted in genbank format.

Abbreviations

AnGST: Analyzer of gene and species tree; CDS: Coding sequences; EPS: Exopolysaccharide; HAP: Host associated polymorphism; HGT: Horizontal gene transfer; HTH: Helix turn helix; INDEL: Insertion deletion; MDR: Multidrug resistant; MLST: Multilocus sequence typing; MRCA: Most recent common ancestor; MUMi: Maximum unique matches index; NPB: Not pathogenic to banana; NS-SNP: Non-synonymous polymorphism; OMA: Orthologous matrix; RSSC: *R. solanacearum* species complex; T1SS: Type II secretion system; T3e: Type III effector; T3SS: Type III secretion system.

Page 10 of 11

Competing interests

The authors declare that they have no competing interests.

Authors' contributions

The work presented resulted from collaboration between all authors and each author has participated sufficiently in the work to take public responsibility for the content. PP defined the research theme. FA, GC and PP performed the virulence bioassay. DR contributed to identify the repertoire of T3e. FA and PP realized the genes annotation. FA carried out all the bioinformatics analysis. FA, CA and PP drafted the article, CA and TL participated in revising it critically for intellectual content. Each author gave final approval of the version of the manuscript to be published.

Acknowledgements

The European Union (ERDF), Conseil Régional de La Réunion, the French Agence Nationale de la Recherche and CIRAD provided financial support. ANSES secured part of the doctoral fellowship to F. Ailloud (contract Number 11-237/BSL). We also thank B. Vinatzer (Virginia Tech, USA) for providing the early genomic sequence of strain UW491.

Author details

 ¹CIRAD, UMR PVBMT, F-97410 Saint-Pierre, La Réunion, France. ²Department of Plant Pathology, University of Wisconsin-Madison, Madison, WI, USA.
 ³Anses - Plant Health Laboratory, F-97410 Saint-Pierre, La Réunion, France.
 ⁴Institut de Génomique, Genoscope, Commissariat à l'Energie Atomique (CEA), Evry, Paris, France. ⁵Département de Santé des Plantes et Environnement, (SPE) Inra, Paris, France.

Received: 26 November 2014 Accepted: 20 March 2015 Published online: 08 April 2015

References

- Hayward AC. Biology and epidemiology of bacterial wilt caused by Pseudomonas solanacearum. Annu Rev Phytopathol. 1991;29:65–87.
- Denny T. Plant pathogenic Ralstonia species. In. Plant-associated bacteria. Samuel S. Gnanamanickam, editor: Springer Netherlands; 2006: p. 573–644.
- Fegan M, Taghavi M, Sly, LI, Hayward AC. Phylogeny, diversity and molecular diagnostics of Ralstonia solanacearum. In. Bacterial Wilt Disease: Molecular and Ecological Aspects. Prior P, editor INRA; 1998: 19–33.
- Guidot A, Coupat B, Fall S, Prior P, Bertolla F. Horizontal gene transfer between *Ralstonia solanacearum* strains detected by comparative genomic hybridization on microarrays. ISME J. 2009;3(5):549–62.
- Remenant B, de Cambiaire JC, Cellier G, Jacobs JM, Mangenot S, Barbe V, et al. *Ralstonia syzygii*, the blood disease bacterium and some Asian *R. Solanacearum* strains form a single genomic species despite divergent lifestyles. PLoS One. 2011;6(9):e24356.
- Genin S, Denny TP. Pathogenomics of the *Ralstonia solanacearum* species complex. Annu Rev Phytopathol. 2012;50:67–89.
- Peeters N, Guidot A, Vailleau F, Valls M. Ralstonia solanacearum, a widespread bacterial plant pathogen in the post-genomic era. Mol Plant Pathol. 2013;14(7):651–62.
- Poueymiro M, Cunnac S, Barberis P, Deslandes L, Peeters N, Cazale-Noel AC, et al. Two type III secretion system effectors from *Ralstonia solanacearum* GMI1000 determine host-range specificity on tobacco. Mol Plant Microbe Interact. 2009;22(5):538–50.
- Lavie M, Shillington E, Eguiluz C, Grimsley N, Boucher C. PopP1, a new member of the YopJ/AvrRxv family of type III effector proteins, acts as a host-specificity factor and modulates aggressiveness of *Ralstonia solanacearum*. Mol Plant Microbe Interact. 2002;15(10):1058–68.
- Remigi P, Anisimova M, Guidot A, Genin S, Peeters N. Functional diversification of the GALA type III effector family contributes to *Ralstonia solanacearum* adaptation on different plant hosts. New Phytol. 2011;192(4):976–87.
- Sole M, Popa C, Mith O, Sohn KH, Jones JD, Deslandes L, et al. The awr gene family encodes a novel class of *Ralstonia solanacearum* type III effectors displaying virulence and avirulence activities. Mol Plant Microbe Interact. 2012;25(7):941–53.
- Remenant B, Coupat-Goutaland B, Guidot A, Cellier G, Wicker E, Allen C, et al. Genomes of three tomato pathogens within the *Ralstonia solanacearum* species complex reveal significant evolutionary divergence. BMC Genomics. 2010;11:379.

- 13. Peeters N, Carrere S, Anisimova M, Plener L, Cazale AC, Genin S. Repertoire, unified nomenclature and evolution of the Type III effector gene set in the *Ralstonia solanacearum* species complex. BMC Genomics. 2013;14:859.
- 14. Cellier G, Prior P. Deciphering phenotypic diversity of *Ralstonia solanacearum* strains pathogenic to potato. Phytopathology. 2010;100(11):1250–61.
- Wicker E, Grassart L, Coranson-Beaudu R, Mian D, Guilbaud C, Fegan M, et al. Ralstonia solanacearum strains from Martinique (French West Indies) exhibiting a new pathogenic potential. Appl Environ Microbiol. 2007;73(21):6790–801.
- Cellier G, Remenant B, Chiroleu F, Lefeuvre P, Prior P. Phylogeny and population structure of brown rot- and Moko disease-causing strains of *Ralstonia* solanacearum phylotype II. Appl Environ Microbiol. 2012;78(7):2367–75.
- Baltrus DA, Nishimura MT, Romanchuk A, Chang JH, Mukhtar MS, Cherkis K, et al. Dynamic evolution of pathogenicity revealed by sequencing and comparative genomics of 19 *Pseudomonas syringae* isolates. PLoS Pathog. 2011;7(7):e1002132.
- Jalan N, Aritua V, Kumar D, Yu F, Jones JB, Graham JH, et al. Comparative genomic analysis of *Xanthomonas axonopodis* pv. citrumelo F1, which causes citrus bacterial spot disease, and related strains provides insights into virulence and host specificity. J Bacteriol. 2011;193(22):6342–57.
- Bogdanove AJ, Koebnik R, Lu H, Furutani A, Angiuoli SV, Patil PB, et al. Two new complete genome sequences offer insight into host and tissue specificity of plant pathogenic *Xanthomonas* spp. J Bacteriol. 2011;193(19):5450–64.
- Deloger M, El Karoui M, Petit MA. A genomic distance based on MUM indicates discontinuity between most bacterial species and genera. J Bacteriol. 2009;191(1):91–9.
- Bertolla F, Van Gijsegem F, Nesme X, Simonet P. Conditions for natural transformation of *Ralstonia solanacearum*. Appl Environ Microbiol. 1997;63(12):4965–8.
- Widjaja I, Lassowskat I, Bethke G, Eschen-Lippold L, Long HH, Naumann K, et al. A protein phosphatase 2C, responsive to the bacterial effector AvrRpm1 but not to the AvrB effector, regulates defense responses in *Arabidopsis*. Plant J. 2010;61(2):249–58.
- Gilbert LA, Ravindran S, Turetzky JM, Boothroyd JC, Bradley PJ. Toxoplasma gondii targets a protein phosphatase 2C to the nuclei of infected host cells. Eukaryot Cell. 2007;6(1):73–83.
- Hajri A, Pothier JF, Fischer-Le Saux M, Bonneau S, Poussier S, Boureau T, et al. Type three effector gene distribution and sequence analysis provide new insights into the pathogenicity of plant-pathogenic *Xanthomonas arboricola*. Appl Environ Microbiol. 2012;78(2):371–84.
- Zumaquero A, Macho AP, Rufian JS, Beuzon CR. Analysis of the role of the type III effector inventory of *Pseudomonas syringae* pv. phaseolicola 1448a in interaction with the plant. J Bacteriol. 2010;192(17):4474–88.
- Deslandes L, Genin S. Opening the *Ralstonia solanacearum* type III effector tool box: insights into host cell subversion mechanisms. Curr Opin Plant Biol. 2014;20C:110–7.
- Mukaihara T, Tamura N, Iwabuchi M. Genome-wide identification of a large repertoire of *Ralstonia solanacearum* type III effector proteins by a new functional screen. Mol Plant Microbe Interact. 2010;23(3):251–62.
- Milling A, Meng F, Denny TP, Allen C. Interactions with hosts at cool temperatures, not cold tolerance, explain the unique epidemiology of *Ralstonia solanacearum* race 3 biovar 2. Phytopathology. 2009:99(10):1127–34.
- Tseng TT, Tyler BM, Setubal JC. Protein secretion systems in bacterial-host associations, and their description in the Gene Ontology. BMC Microbiol. 2009;9 Suppl 1:S2.
- 30. Expert D. Withholding and exchanging iron: Interactions Between Erwinia spp. and Their Plant Hosts. Annu Rev Phytopathol. 1999;37:307–34.
- Ratledge C, Dover LG. Iron metabolism in pathogenic bacteria. Annu Rev Microbiol. 2000;54:881–941.
- Boch J, Scholze H, Schornack S, Landgraf A, Hahn S, Kay S, et al. Breaking the code of DNA binding specificity of TAL-type III effectors. Science. 2009;326(5959):1509–12.
- Mukaihara T, Tamura N. Identification of novel *Ralstonia solanacearum* type III effector proteins through translocation analysis of *hrpB*-regulated gene products. Microbiology. 2009;155(Pt 7):2235–44.
- Vuong C, Kocianova S, Voyich JM, Yao Y, Fischer ER, DeLeo FR, et al. A crucial role for exopolysaccharide modification in bacterial biofilm formation, immune evasion, and virulence. J Biol Chem. 2004;279(52):54881–6.

- Milling A, Babujee L, Allen C. *Ralstonia solanacearum* extracellular polysaccharide is a specific elicitor of defense responses in wilt-resistant tomato plants. PLoS One. 2011;6(1):e15853.
- Huillet E, Velge P, Vallaeys T, Pardon P. LadR, a new PadR-related transcriptional regulator from *Listeria monocytogenes*, negatively regulates the expression of the multidrug efflux pump MdrL. FEMS Microbiol Lett. 2006;254(1):87–94.
- Li Y, Peng Q, Selimi D, Wang Q, Charkowski AO, Chen X, et al. The plant phenolic compound p-coumaric acid represses gene expression in the *Dickeya dadantii* type III secretion system. Appl Environ Microbiol. 2009;75(5):1223–8.
- Gueneron M, Timmers AC, Boucher C, Arlat M. Two novel proteins, PopB, which has functional nuclear localization signals, and PopC, which has a large leucine-rich repeat domain, are secreted through the hrp-secretion apparatus of *Ralstonia solanacearum*. Mol Microbiol. 2000;36(2):261–77.
- Zuluaga AP, Puigvert M, Valls M. Novel plant inputs influencing *Ralstonia* solanacearum during infection. Front Microbiol. 2013;4:349.
- Jacobs JM, Babujee L, Meng F, Milling A, Allen C. The in planta transcriptome of Ralstonia solanacearum: conserved physiological and virulence strategies during bacterial wilt of tomato. MBio. 2012;3(4):e00114–12.
- Bolger AM, Lohse M, Usadel B. Trimmomatic: a flexible trimmer for Illumina sequence data. Bioinformatics. 2014;30(15):2114–20.
- 42. Zerbino DR, Birney E. Velvet: algorithms for de novo short read assembly using de Bruijn graphs. Genome Res. 2008;18(5):821–9.
- Vallenet D, Labarre L, Rouy Z, Barbe V, Bocs S, Cruveiller S, et al. MaGe: a microbial genome annotation system supported by synteny results. Nucleic Acids Res. 2006;34(1):53–65.
- Xu J, Zheng HJ, Liu L, Pan ZC, Prior P, Tang B, et al. Complete genome sequence of the plant pathogen *Ralstonia solanacearum* strain Po82. J Bacteriol. 2011;193(16):4261–2.
- Kurtz S, Phillippy A, Delcher AL, Smoot M, Shumway M, Antonescu C, et al. Versatile and open software for comparing large genomes. Genome Biol. 2004;5(2):R12.
- 46. Roth AC, Gonnet GH, Dessimoz C. Algorithm of OMA for large-scale orthology inference. BMC Bioinformatics. 2008;9:518.
- Pellegrini M, Marcotte EM, Thompson MJ, Eisenberg D, Yeates TO. Assigning protein functions by comparative genome analysis: protein phylogenetic profiles. Proc Natl Acad Sci U S A. 1999;96(8):4285–8.
- 48. Edgar RC. MUSCLE: multiple sequence alignment with high accuracy and high throughput. Nucleic Acids Res. 2004;32(5):1792–7.
- Price MN, Dehal PS, Arkin AP. FastTree: computing large minimum evolution trees with profiles instead of a distance matrix. Mol Biol Evol. 2009;26(7):1641–50.
- 50. David LA, Alm EJ. Rapid evolutionary innovation during an Archaean genetic expansion. Nature. 2011;469(7328):93–6.

Submit your next manuscript to BioMed Central and take full advantage of:

- Convenient online submission
- Thorough peer review
- No space constraints or color figure charges
- Immediate publication on acceptance
- Inclusion in PubMed, CAS, Scopus and Google Scholar
- Research which is freely available for redistribution

) BioMed Central

Submit your manuscript at www.biomedcentral.com/submit

Conclusion

Peu de différences ont donc été identifiées entre les écotypes Moko, Brown rot et NPB. De façon intéressante, les divergences observées concernent tout de même plusieurs facteurs de virulence dont des T3E qui ont été associés à la détermination du spectre d'hôte : AvrA (RipAA) module la virulence sur différentes espèces de tabac et GALA4 restreint la virulence sur *A. thaliana* en activant le PTI ('PAMP Triggered Immunity'). Des analyses fonctionnelles ont été effectuées mais n'ont cependant pas pu être intégrées dans la publication dans les délais impartis. Deux T3E présentent des différences entre les Moko et les NPB : RipAA et RipAN.

Le gène *ripAA* est présent chez toutes les souches Moko mais absent des souches NPB : une souche Moko mutant chez laquelle *ripAA* a été supprimé ainsi qu'une souche NPB dans laquelle *ripAA* a été rajouté ont donc été produites. La délétion de ce gène chez les Moko nous permet de déterminer si cet effecteur contribue à la virulence chez le bananier ou bien la tomate tandis que son ajout chez les NPB permet de savoir s'il restreint la virulence chez le bananier ; la caractérisation fonctionnelle permet donc de déterminer si RipAA est facteur de virulence ou d'avirulence dans le cadre de ce modèle. Dans le cadre d'analyses préliminaires, un changement phénotypique majeur a été observé : la souche Moko délétée pour *ripAA* perd complètement son pouvoir pathogène chez le bananier tandis que la souche NPB complémentée avec *ripAA* n'a pas acquis de virulence sur bananier (**Figure 21**).

Le gène *ripAN* est présent chez les souches Moko et NPB mais présente un polymorphisme non-synonyme qui distingue ces deux groupes (HAP) (**Figure 22**) : des souches mutantes Moko et NPB chez lesquelles *ripAN* est absent et des souches mutantes Moko et NPB complémentées avec le gène contenant le polymorphisme NPB et Moko, ont été construites respectivement. Aucun changement phénotypique n'a été observé suite à la délétion ou à la modification du polymorphisme. Ces facteurs de virulence étant des T3E, il est donc probable qu'ils jouent malgré tout un rôle dans le pouvoir pathogène, ce rôle ne semble cependant pas être assez



Figure 21 – Phénotypage (inoculation par le pseudotronc) des mutants de délétion du T3E RipAA. De droite a gauche : souche Moko IIB4 sauvage ; souche Moko IIB4 $\Delta ripAA$; souche Moko IIB4 $\Delta ripAA$; souche NPB sauvage. (Source : P. Prior)



Figure 22 – Exemple d'un polymorphisme associé à la variation du spectre d'hôte (HAP) chez le gène d'un effecteur de type III (*ripAN*).

important pour modifier le spectre d'hôte des souches Moko et NPB. Bien que *ripAA* apparaisse désormais comme un déterminant primaire du pouvoir pathogène sur le bananier, cette étude préliminaire va être reproduite en y incluant les mutants de délétion complémenté par *ripAA*.

De façon similaire aux NPB, un unique T3E, *ripAU*, semble avoir été perdu lors de la divergence des Brown rot. Le nombre de T3E polymorphiques par rapport aux souches Moko est cependant bien plus important. Ce résultat pouvait être en partie attendu en considérant la distance génétique plus importante entre les lignées IIB-1 et IIB-3 qu'entre les lignées IIB-4-Moko et IIB-4-NPB. Néanmoins, l'analyse des polymorphismes prend en compte toutes les lignées Moko qui sont également éloignées génétiquement au sein du phylotype II, ces résultats indiquent donc que des mutations de sites conservées dans de nombreux T3E ont probablement été sélectionnées chez les Brown rot. En sachant que l'adaptation de cet écotype aux conditions tempérées est entièrement dépendante de l'environnement de la pomme de terre, il est possible que l'évolution de facteurs de virulence ait joué un rôle dans l'apparition de ce phénotype.

A l'exception du cas de *ripAA*, ces travaux n'ont donc pas permis de fournir une réponse définitive à la question du spectre d'hôte. Le modèle d'étude, constitué notamment par les groupes Moko et NPB, reste un modèle valide et de choix. En effet, les divergences phénotypiques entre ces deux groupes sont flagrantes et l'analyse des génomes complets a définitivement démontré la forte proximité génétique de ces deux groupes. Plusieurs directions sont envisageables pour poursuivre les travaux sur ce modèle. La finition des génomes déjà séquencés permettrait d'augmenter la résolution des analyses comparatives et pourrait potentiellement permettre de caractériser de nouvelles différences plus subtiles. Le séquençage de souches additionnelles appartenant à de nouvelles lignées Moko récemment décrites au Brésil (Albuquerque et al., 2014) enrichirait également l'analyse. La caractérisation fonctionnelle approfondie des T3E représenterait également une avancée majeure dans la compréhension des mécanismes fins de la virulence. La détermination de leur cible et de leur localisation *in planta* ainsi que les conditions et la cinétique de leur expression et sécrétion permettraient de mieux comprendre leur rôle précis lors de colonisation et de déchiffrer les phénomènes de redondance.

Finalement, nous avons identifié plusieurs régulateurs transcriptionnels qui laissent à penser que l'adaptation à l'hôte repose plus sur des modifications de l'expression plutôt que sur des modifications du génome. Mes travaux se sont donc orientés vers la caractérisation des différences d'expression entre les souches Moko et NPB sur différents hôtes et milieux de culture.

Chapitre 3 – Addendum Développement d'un outil diagnostic

Mes travaux précédents ont porté sur la caractérisation génomique de groupes d'intérêt chez *R. solanacearum* afin d'identifier des gènes candidats associés à la détermination du spectre d'hôte. Bien qu'elles aient été entreprises dans une perspective fondamentale, les méthodes bioinformatiques mises en place dans le cadre de cette étude peuvent être utilisées à des fins de recherche appliquée. En effet, les techniques de génomique comparative sont également adaptées à l'identification de marqueurs spécifiques permettant de distinguer les groupes et lignées a valeur épidémiologique au sein du complexe d'espèce. Dans cette perspective, une collaboration entre l'Anses (G. Cellier) et le CIRAD (I. Robène, S. Arribat, J. Barthet, P. Grygiel) a permis le développement d'une puce à ADN présentant les caractéristiques requises pour une utilisation dans le domaine du diagnostic : faible coût d'achat et d'investissement, protocole rapide, résultats répétables.

Mon implication dans ces travaux a concerné principalement la sélection de certains répertoires de gènes spécifiques des lignées d'intérêt et la participation aux discussions relatives à l'évolution du protocole expérimental en fonction des résultats intermédiaires. La puce ainsi développée est basée sur la technologie ArrayTube (Alere Technologies) pouvant regrouper jusqu'à 196 sondes sur un support de 3x3mm placé au fond d'un tube d'une taille équivalente a celle d'un Eppendorf 2ml (**Figure 23**). Les échantillons à diagnostiquer doivent se présenter sous forme d'ADN, extrait par exemple de colonies isolées sur milieu solide à partir de tissu végétal infecté, et sont préparés avec des techniques de biologie moléculaire de routine pour une durée totale de 3h. Finalement, la lecture de la puce consiste en une détection colorimétrique (marquage par un conjugué HRP) qui s'effectue à l'aide d'un scanner doté d'une caméra CCD compact nécessitant peu de maintenance.



Figure 23 – A. Représentation schématique d'un ArrayTube (Alere Technologies) B. Exemple d'une image obtenue lors de la lecture de la puce.

La technologie ArrayTube est déjà utilisée dans le cas des pathogènes humains, comme par exemple pour la distinction des nombreux variants du virus de la grippe *Haemophilus influenzae*. Elle apparait donc adaptée pour établir un diagnostic précis et capable d'appréhender la diversité génétique du complexe d'espèce.

Le développement de la puce a naturellement débuté par le design de sondes spécifiques à chacune des lignées génétiques du complexe d'espèce pouvant avoir un intérêt stratégique en terme de diagnostic et d'études épidémiologiques. Les génomes disponibles publiquement, ainsi que ceux séquencés dans le cadre des travaux de génomique comparative précédent (26 génomes au total) ont été utilisés comme point de départ pour le design des sondes par les logiciels ArrayOligoSelector (Bozdech et al., 2003) et OligoArray (Rouillard et al., 2003). Les résultats des deux logiciels ont été sélectionnés et triés afin d'obtenir un design homogène sur les gènes cibles. En effet, les algorithmes étant différents, le design de sondes sur certains gènes ne pouvaient se faire qu'avec un des deux logiciels. Certaines sondes ont été désignées manuellement, notamment pour cibler les amplicons produits par les PCR diagnostiques existantes : 759/760 (universelles *R. solanacearum*); 630/631 (spécifiques Brown rot); 93F/93R (spécifiques Moko) (Cellier et al. 2015 in press). Les sondes candidates ainsi obtenues sont longues de 50pb et ont une température de fusion proche de 80°C. Leur spécificité ainsi que celle des cibles contre lesquelles elles sont dirigées a ensuite été validée in silico par BLAST, puis in vitro par PCR, réduisant le nombre initial de 256 sondes candidates à 100. Au total, 17 groupes d'intérêts peuvent être distingués à l'aide de ces sondes, chaque groupe contient entre 2 et 5 gènes spécifiques et chaque gène est ciblé par 2 sondes distinctes:

- Un groupe « GC » correspondant au core génome de R. solanacearum
- Les phylotypes I, II, III et IV
- La lignée IIA7 de la souche type K60 de l'espèce R. solanacearum
- Les sous-groupes du phylotype II : IIA et IIB
- Les lignées correspondant aux écotypes du phylotype II : IIB-1 (Brown rot), IIB-3 (Moko), IIB-4 (Moko), IIB-4 (NPB), IIA-6 (Moko) et IIA-24 (Moko)
- Les lignées correspondant aux différentes espèces regroupées au sein du phylotype IV : IV-10 (*R. solanacearum*), IV-9 (*R. syzygii*), IV-10 (BDB)

Afin d'optimiser les coûts de développement, la performance des 100 sondes candidates a été évaluée premièrement à l'aide d'une puce sur lame de verre car le laboratoire était déjà en possession du matériel permettant leur hybridation et leur lecture. Contrairement aux puces haute densité de type Affymetrix, ces puces nécessitent une amplification préalable des cibles avant hybridation. Au total, 50 puces sur lame de verre ont ainsi été spottées par la Plateforme GeT Biopuces de Toulouse (**Figure 24**). Cette étape de criblage a permis notamment de vérifier que chaque sonde s'hybridait correctement et exclusivement avec son groupe cible respectif. En effet, l'hybridation dépend de nombreux paramètres expérimentaux (force ionique, concentration en ADN, fréquence et conditions de lavages, etc) et la prédiction des sondes *in silico* ne permet pas de garantir son efficacité malgré les étapes de validation par BLAST et PCR.

La validation des sondes candidates s'est ensuite poursuivie directement sur ArrayTube. Chaque sonde a été spottée en trois exemplaires repartis aléatoirement afin de tester la répétabilité, tout en évitant un biais éventuel dû a la position du spot sur la puce. De manière similaire aux puces sur lame de verre, les ArrayTube nécessitent une amplification préalable des cibles. Lors de cette étape de développement, l'amplification des cibles par PCR linéaire a été testée et validée afin d'adapter le protocole au contexte particulier du diagnostic. En effet, cette technique permet l'obtention d'un amplicon à l'aide d'une seule amorce par cible et le



Figure 24 - A. Puces sur lame de verre. B. Agrandissement.

multiplexage de plusieurs centaines d'amorces en une seule réaction. Les volumes de réactifs, le temps de manipulation et les coûts s'en trouvent donc réduits comparés à une PCR conventionnelle équivalente. La validation sur ArrayTube permet non seulement de confirmer que les sondes candidates demeurent spécifiques dans les conditions expérimentales d'hybridation propres à cette technologie, mais également de déterminer le cutoff d'intensité du signal permettant de distinguer les spots positifs des négatifs à l'aide de méthodes statistiques (courbes Receiver Operating Characteristic, seuil de Youden, etc). A l'issue de cette étape, 35 sondes ont été validées.

Le prototype final de cette puce de type ArrayTube peut donc distinguer 17 groupes au sein de RSSC à l'aide de 35 sondes spottées en triplicat. La position phylogénétique d'une souche dans le RSCC est ainsi estimée a un niveau de précision s'étendant au minimum du phylotype et potentiellement, jusqu'au sequevar. Dans une certaine mesure, la détection de lignées associées à des écotypes permet également de prédire le potentiel infectieux d'une souche. En dehors de son application diagnostic direct, cette puce pourrait rendre possible un suivi épidémiologique de *R. solanacearum* bien plus précis que celui permis actuellement par les méthodes officielles. Bien que le prototype final de cet ArrayTube coûte environ 60 € à l'unité, ce qui représente un coût conséquent comparé à une PCR multiplexe (dans le contexte du diagnostic), 35x3 réactions sont réalisées simultanément sur ce prototype. Par ailleurs, 91 spots sont encore libres sur la puce et pourront, dans le futur, être occupés par des sondes dirigées contre des lignées émergentes et/ou encore non caractérisées. Par exemple, de nouvelles lignées Moko ont été récemment identifiées au Brésil (Albuquerque, et al. 2014). Eventuellement, ces spots pourraient aussi être occupés par des sondes détectant d'autres phytopathogènes ayant des hôtes communs avec *R. solanacearum*, afin de faire de cette étude un outil de diagnostic multi-organisme.

Comparé aux méthodes de diagnostic officielles basées sur des PCR, l'ArrayTube possède de nombreux avantages. La détection de chaque cible par deux sondes spottées chacune en trois exemplaires en fait une méthode robuste et le nombre total de cibles détectées en fait une méthode haut débit. La simplicité du protocole et la standardisation des réactifs et du matériel de lecture permettent une grande répétabilité. Cette technologie possède cependant certaines limitations concernant notamment le matériel de départ. Quand les PCR diagnostic actuelles peuvent s'effectuer directement sur une colonie isolée sans réaliser d'extraction ADN, voire directement a partir d'une suspension de tissu végétal infecté, la puce nécessite obligatoirement un isolement, de grande quantité d'ADN et une amplification intermédiaire. Néanmoins, contrairement aux virus phytopathogènes qui ne nécessitent pas de disposer du virus purifié, l'isolement sur milieu solide est toujours requis pour l'établissement d'un diagnostic bactérien officiel. Par la suite, la sensibilité et la spécificité de la puce seront caractérisées à plus grande échelle par des procédures certifiées afin de pouvoir en publier les résultats et, éventuellement, les intégrer dans la démarche officielle du diagnostic de *R. solanacearum*.

Chapitre 4 – Transcriptomique in planta

Le paysage transcriptomique chez *R. solanacearum* a été défini principalement par des travaux sur l'expression des facteurs de virulence (Allen et al., 1997; Brito et al., 1999) et leur modulation par des stimuli environnementaux, comme le contact avec les cellules végétales (Aldon et al., 2000), la densité cellulaire (Clough et al., 1997) ou des études de type IVET (Brown and Allen, 2004). Des travaux plus récents, utilisant des méthodes plus modernes, ont cependant démontré que certains schémas bien établis sont bien plus complexes qu'imaginé auparavant. Ces travaux prouvent, par exemple, que les T3E ne sont pas exclusivement exprimés uniquement durant les étapes précoces, mais tout au long de l'infection (Monteiro et al., 2012), ou encore que le régulateur HrpG, responsable en partie de l'expression des T3E, n'est pas induit uniquement par le contact avec les plantes mais également par des signaux encore inconnus (Zuluaga et al., 2013).

A l'aide d'une puce à ADN, une image globale du transcriptome de la souche modèle GMI1000 a pu être obtenue au cours de l'infection d'un plant de tomate (Jacobs et al., 2012). De la même manière qu'en génomique, notre connaissance transcriptomique à l'échelle du RSSC reste donc très limitée. Suite aux conclusions des analyses de génomique comparatives entreprises précédemment, je me suis donc intéressé aux différences d'expression génique entre nos deux écotypes modèles (souches Moko vs. NPB). En effet, les faibles différences de séquence (polymorphismes) et de contenu en gènes entre les souches Moko et NPB nous ont conduit a émettre l'hypothèse que la variation du spectre d'hôte entre ces deux écotypes est probablement associée à des divergences transcriptomiques plutôt que du contenu en gènes (Ailloud et al. 2015). Les méthodologies associées à l'étude du transcriptome étant encore fastidieuses et coûteuses, le modèle expérimental a été restreint à deux souches de la lignée IIB-4 : une souche Moko (UW163) et une souche NPB (RUN302). Au sein de cette lignée, les souches Moko et NPB partagent plus de 90% de leurs génomes et plus de 80% des loci communs sont identiques au niveau nucléotidique. Cette forte similarité permet donc de comparer directement les niveaux d'expression de ces deux souches malgré leur spectre d'hôte divergent (**Figure 25**). Afin d'identifier les différences entre ces deux souches de la manière la plus exhaustive possible, l'expression génique de *R. solanacearum* a été caractérisée dans les conditions suivantes à des densités cellulaires similaires (10⁸ a 10⁹ CFU par ml de milieu ou par g de tissu végétal):

- **Milieu riche liquide CPG** : ce milieu est communément utilisé pour cultiver *R. solanacearum* et a notamment été utilisée comme point de comparaison dans l'étude du transcriptome *in planta* de GMI1000 chez la tomate.
- **Milieu minimum BMM** : ce milieu imite en partie l'environnement végétal et induit l'expression des T3E.
- **Tomate** : cet hôte est commun aux deux souches et permet de déterminer si les deux souches expriment les mêmes facteurs de virulence quand elles colonisent un environnement identique.
- **Bananier**, uniquement pour la souche Moko : cet hôte n'est infecté que par les souches Moko.
- **Melon**, uniquement pour la souche NPB : cet hôte n'est infecté que par les souches NPB.

Au total, chaque souche est donc testée dans quatre conditions. Chaque condition a été répétée trois fois (réplicats biologiques) donnant 24 échantillons d'ARN séquencés en double (réplicats techniques). Certaines étapes ont été limitantes. Premièrement, pour les conditions *in planta*, il est nécessaire de prélever des plants présentant théoriquement des symptômes précoces de flétrissement (D.I. = 1) afin d'obtenir des culots bactériens correspondant aux densités cellulaires requises de 10⁸ a 10⁹ CFU/g de tissu. En pratique, certains plants auront une densité bactérienne inferieure à celle requise en présence de symptômes ou bien supérieure sans symptômes apparent et cela malgré l'utilisation de plants homogènes et l'infection avec une dose d'inoculum contrôlée. Ce phénomène est d'autant plus amplifié que les souches sélectionnées sont plus agressives que les souches modèles généralement utilisées pour des tests de virulence. Sur tomate, les symptômes peuvent progresser de D.I. = 1 (25% des feuilles flétries) à 3 (75% des feuilles flétries) en moins d'une journée. De plus, l'indice de notation des symptômes n'est pas vraiment adapté au bananier. En effet, le flétrissement progresse de manière





Figure 25 – Représentation schématique du projet transcriptomique.

bien moins radicale sur bananier que sur la tomate ou le melon, l'équivalent de D.I. = 1 correspond sommairement à une seule feuille commençant à flétrir et pouvant être confondu avec la senescence normale de la plante (en chambre climatique). Deuxièmement, l'extraction d'ARN et leur séquençage par RNAseq requièrent des conditions de stérilité strictes et l'utilisation de consommables adaptés. Certains échantillons obtenus lors d'une première expérience au Pole de Protection des Plantes (3P) ne possédaient pas le niveau de qualité nécessaire pour être séquencés. Les échantillons obtenus lors d'une seconde expérience à l'Université du Wisconsin (Laboratoire de Caitilyn Allen) se sont révélés d'une qualité bien plus adéquate. En effet, les conditions de laboratoire, mais surtout le transport international des échantillons sur carboglace du a l'absence d'un centre de séquençage sur l'ile de la Réunion, sont probablement à l'origine de l'échec partiel de la première expérience.

A l'aide de méthodes statistiques se basant sur un modèle de distribution binomiale négative, les transcriptomes obtenus peuvent être comparés pair- à -pair afin d'identifier les gènes différentiellement exprimés entre chaque conditions. Avec quatre conditions par souche, cela revient à 28 comparaisons possibles. Toutes les comparaisons ne répondent cependant pas à des questions ayant une signification biologique. La comparaison du transcriptome d'une même souche dans des conditions différentes fournit surtout des indications sur l'influence de l'environnement, tandis que la comparaison des transcriptomes chez deux souches dans des conditions équivalentes indique plutôt les divergences entre écotypes. Par exemple, les niveaux d'expression en milieu riche peuvent être comparés avec ceux observés *in planta* afin d'identifier les gènes potentiellement induits sous le contrôle de la plante; et l'expression différentielle entre les deux souches au sein de la tomate reflète la conservation des stratégies de virulence au sein d'un même environnement.

CES DONNEES ONT ETE DECRITES ET INTERPRETEES SOUS LA FORME D'UN PROJET DE PUBLICATION QUI SERA SOUMIS A LA REVUE **BMC** GENOMICS ET DONT LE TITRE PRELIMINAIRE EST: « *IN PLANTA* COMPARATIVE TRANSCRIPTOMICS OF HOST-ADAPTED STRAINS OF *RALSTONIA SOLANACEARUM* ».

- 1 In planta comparative transcriptomics of host-adapted strains of Ralstonia
- 2 solanacearum
- 3 Florent Ailloud¹², Tiffany Lowe³, Caitilyn Allen³, and Philippe Prior^{1, 4}
- 4 Author's affiliations
- ¹ CIRAD, UMRC53 PVBMT, F-97410, Saint-Pierre, La Réunion, France
- 6 ²Anses Plant Health Laboratory, F-97410, Saint-Pierre, La Réunion, France
- ³Department of Plant Pathology, University of Wisconsin-Madison, Madison, WI USA
- 8 ⁴Département de Santé des Plantes et Environnement (SPE), Inra, France
- 9 **Corresponding author and E-mail address**: Philippe Prior, <u>philippe.prior@cirad.fr</u>

10 Abstract

11 Background

Ralstonia solanacearum is an economically important plant pathogen with an unusually large host range. Moko and NPB are groups of closely related strains that are adapted to distinct hosts. Previous studies have uncovered very few genomic differences that could account for the host range variation of these pathotypes. To better understand the basis of host specificities, we used RNAseq to obtain *R. solanacearum* transcriptome profiles of a Moko strain and an NPB strain under *in vitro* and *in planta* conditions.

18 Results

19 RNAs were sequenced from cells grown in rich and minimal media, as well as from bacteria 20 extracted from mid-stage infected tomato, banana and melon plants. Differential expression 21 between a pair of conditions was computed to represent gene expression differences between 22 Moko and NPB. We found that T3Es were globally up-regulated upon plant cell contact in the 23 NPB strain compared with the Moko strain. Siderophore biosynthesis and nitrogen 24 metabolism genes were highly differentially expressed during the colonization of distinct, 25 pathotype-specific hosts.

26 Conclusions

This study provides the first report of differential gene expression associated with host range variation. Despite minimal genomic divergence, the pathogenicity of Moko and NPB strains is characterized by striking differences in their expression of virulence- and metabolismrelated genes.

Keywords: *Ralstonia solanacearum*, Moko, NPB, host range, transcriptomics, differential
 expression

33 Background

Although the virulence mechanisms of model strains such as GMI1000 have been extensively investigated in model host plants such as *Solanum lycopersicum* (tomato) or *Arabidopsis thaliana, R. solanacearum* is part of a genetically diverse species complex (RSSC) with a cumulative host range that includes more than 250 vegetal species [1]. Very little is known about the prevalence of virulence factors in the RSSC or their contribution to pathogenicity in a large array of hosts. Moreover, recent *in planta* studies have tended to disprove models of pathogenicity regulation that were previously validated *in vitro* [2, 3].

41 Within the RSSC, several groups of strains appear to have undergone adaptation to specific 42 hosts and are grouped in distinct phylogenetic lineages. The most studied group is the brown 43 rot pathotype (IIB-1), which corresponds to strains that are adapted to potatoes in temperate 44 climates [4]. Less studied groups include the Moko and NPB pathotypes. The Moko 45 pathotype is a polyphyletic group (IIB3, IIB4, IIA6, IIA24, etc.) of strains that are pathogenic to banana [4]. The NPB pathotype is monophyletic group that is similar the IIB4 Moko 46 47 lineage but has lost the ability to infect banana; however, it is virulent towards several 48 members of the *Cucurbitaceae* family [5, 6]. Remarkably, most of the strains in these groups 49 are also pathogenic to tomato plants. The host spectrums of Moko and NPB strains thus 50 comprise both common and exclusive host plants. Because of their genetic closeness on the 51 scale of the RSSC, these strains represent an interesting experimental model that provides a 52 unique opportunity to pinpoint the mechanisms associated with host specificity.

We previously used a comparative genomics analysis to characterize the gene content and sequence differences between Moko and NPB strains from the IIB4 lineage. The lack of significant differences between these strains, particularly with respect to virulence factors, led us to hypothesize that the host range variations between Moko and NPB strains are associated with significant differences in gene expression (Ailloud et al. 2015, *submitted*).

58 This work represents the first report of transcriptomic differences associated with host range 59 variation. It is also the first gene expression analysis of R. solanacearum strains from the 60 Moko and NPB ecotypes assigned to the IIB4 lineage. RNA samples were extracted from the 61 Moko strain UW163 and the NPB strain RUN302 under biologically relevant conditions: 62 minimal medium, rich medium, tomato infection and either banana infection (UW163) or melon infection (RUN302). Differential gene expression was inferred from pairwise 63 comparisons that were organized to determine either the influence of different environments 64 65 on individual pathotypes or differences in gene expression between pathotypes. Striking

- 66 differences in the induction levels of type III effector genes upon plant cell contact, as well as
- 67 the differential regulation of genes encoding proteins involved in siderophore biosynthesis
- and nitrogen metabolism, were observed between the two pathotypes.

69 Materials and methods

70 Bacterial strains and growth conditions

The R. solanacearum strains UW163 and RUN302 were used in this study. UW163 was isolated in 1967 from plantain in Peru; it belongs to the phylotype IIB4 and to the banana Moko disease-causing ecotype. RUN302 was isolated in 1999 from cucumber in Brazil; it belongs to the phylotype IIB4 and to the NPB ecotype, a pathological variant that is pathogenic towards Cucurbits. Both strains were grown aerobically at 28°C in Boucher's minimal medium (BMM) [7] and rich medium composed of casamino acid, peptone and glucose (CPG) supplemented with yeast extract [8].

78 **RNA extraction for RNAseq**

79 To observe the transcriptomic landscape of the bacterial cells in vitro (i.e., outside plants),

- 80 both strains were grown independently in CPG and BMM to a density of $\sim 6 \times 10^8$ CFU/ml
- 81 (O.D. = 0.8). RNA was extracted from bacterial pellets as described in Jacobs *et al.* 2012 [3].
- 82 Three biological replicates were performed for each condition.

83 To observe the transcriptomic landscape of the bacterial cells during colonization in planta, 84 plants were infected with 5x108 CFU via soil-soak inoculation as described in Cellier et al. 85 2010 [4]. Tomato plants (cv. Bonny Best) were inoculated with either UW163 or RUN302. 86 Banana plants (Cavendish) were inoculated with UW163. Melon plants (cv. Amish) were 87 inoculated with RUN302. Bacteria were extracted from plants stems showing early wilt 88 symptoms at a disease index (D.I.) of 1. Bacteria and RNA were extracted as described in 89 Jacobs et al. 2012 [3]. Only stems containing between 108 and 109 CFU/g of tissue were used 90 for extraction. Three biological replicates were performed for each condition, and each 91 replicate consisted of a pool of RNA extracted from ~15 stems.

- RNA sequencing was carried out by the University of Wisconsin Biotech Center (UWBC).
 One hundred base pair single-end libraries were sequenced on an HiSeq 2000 (Illumina).
 Each library was sequenced twice to provide technical replicates. Read quality was controlled
 with FastQC (www.bioinformatics.bbsrc.ac.uk/projects/fastqc). Low-quality bases and
- 96 adapters were trimmed using Trimmomatic [9].

97 Differential expression analysis

98 Reads from each library were mapped onto their corresponding reference genome using 99 Bowtie2 [10]; the number of uniquely mapped reads for each coding sequences (CDS) was then counted using Bedtools [11]. Differential gene expression between multiple pairs of 100 101 conditions was computed using edgeR [12] and DEseq2 [13]. Only CDS predicted by both 102 methods with an FDR (corrected p-value) < 0.01 and a $-2 > \log FC > 2$ were considered 103 differentially expressed. UW163 accession number EMBL: PRJEB7430; RUN302 accession 104 number EMBL: PRJEB7433. Genome annotations are available on the MicroScope platform 105 (www.genoscope.cns.fr/agc/microscope).

106 Results and Discussion

107 Initial results

The mapping results indicated efficient bacterial extraction and library preparation. For each sample, rRNA or plant RNA contamination was limited, and 60 to 90% of the total sequenced reads were mapped to CDS (> 10 M mapped reads per sample).

Principal component analysis (PCA) of the counts data revealed that the biological and technical replicates were consistent. Differentially expressed genes were obtained by merging the results of the edgeR and DEseq2 packages. Although there were some differences between the two sets of results, as expected, the differences were marginal [14, 15]. An inspection of the MA and volcano plots suggested no bias between the CPM and either the logFC or the FDR adjusted p-value.

DGE was computed between multiple pairs of samples to characterize the differences between the IIB4 Moko and NPB strains *in vitro* and *in planta* during the colonization of several hosts (**Fig. 1**) (**Additional file 1**). Overall, many more differentially expressed genes were observed between CPG and BMM media (~40% of the genome) than in plant-to-plant comparisons (10 to 20% of the genome).

122 To validate our analysis pipeline, the transcriptomic profile in rich medium (CPG) was compared with either minimal medium (BMM) or tomato stems. In both UW163 and 123 124 RUN302 samples, T3SS components and T3E were highly overexpressed in BMM-cultured 125 cells and in plants compared with CPG-cultured cells. These observations are consistent with 126 previous findings that T3SS and T3E expression is not repressed in minimal medium or in tomato stems at high cell densities (> $5x10^8$ CFU/ml) in the phylotype I strain GMI1000 [3]. 127 128 Similar observations were made in the banana and melon samples. Together, these results 129 tended to demonstrate that our bioinformatics pipeline is suitable to analyze our model given

130 our experimental conditions.



Figure 1 – Differential expression across all tested comparison. Grey bars indicate the total number of differentially expressed genes in the comparison. Blue bars indicate the number of genes more expressed in the first condition while orange bars indicate the number of genes more expressed in the second condition.

131 Conserved regulatory pathways in similar environments: Moko vs. NPB in CPG, BMM

132 and tomato plants

Moko and NPB IIB4 strains share more than 90% of their gene content, and 80% of these common genes display perfect nucleotide identity (Ailloud et al. 2015, submitted). By comparing UW163 and RUN302 gene expression in similar environments (CPG, BMM and tomato stems), we were able to characterize the extent to which these small genomic differences have constitutively modified the transcriptomic profiles of these strains. The detailed results are available in **Additional file 2**.

- 139 A total of 4148 genes were never differentially expressed between the Moko and NPB strains 140 in CPG, BMM and tomato stems based on a logFC threshold of ± 2 . Conversely, 47 genes 141 were always differentially expressed in similar environments. These values represent ~90% 142 and only $\sim 1\%$ of the genes shared by the two strains. A major portion of the 1% of genes that 143 were differentially expressed followed the same regulatory patterns in CPG, BMM and 144 tomato plants, indicating that they were always more expressed in the same strain irrespective 145 of the conditions. Notably, genes encoding a complete putative amino acid ABC transporter 146 and the catalase KatB were overexpressed in the NPB strain under all three conditions. KatB 147 is involved in the oxidative stress response during plant infection [16]. Similarly, genes 148 encoding a putative hexuronate transporter ExuT2 and a lysozyme protein were 149 overexpressed in the Moko strain in all conditions. The role of ExuT2 has not been 150 characterized; the transporter ExuT is involved in the uptake of compounds released during 151 cell wall degradation, though it does not contribute directly to wild-type virulence [17]. 152 However, ExuT was not differentially expressed in any of the three conditions.
- 153 An additional 407 genes, or ~9% of the genes shared between the strains exhibited 154 inconsistent expression patterns between the different conditions. These genes were 155 differentially expressed in only one or two of the conditions that were compared. This result 156 can be explained by regulatory pathways that are unique to each strain and are specifically 157 activated by compounds present in only one of the three conditions. Of these genes, 9% were 158 only differentially expressed in tomato stems, 50% only in CPG, and 20% only in BMM. 159 These results could also be due to experimental bias if some parameters were not exactly 160 identical between the Moko and NPB strains in one of the conditions.

161 It should be noted that some computational bias could arise when comparing the UW163 and 162 RUN302 strains due to the use of distinct reference genomes during the mapping process. In 163 this case, the estimation of differentially expressed genes is based on homolog families shared 164 by both strains. Even if homolog families are correctly predicted, a given locus can

- sometimes be fragmented (because it is located on the border of a contig) or have a slightly different START position in one strain compared with the other, which results in more reads being mapped in one locus and eventually gives rise to a false positive.
- Most of the genes shared by the Moko and NPB strains were thus similarly expressed under similar conditions. A total of 10% of the shared genes were differentially expressed to some degree, but only 1% of the differences were seen under all three conditions and could be considered constitutive differences. Taken together, these results suggest that the Moko and NPB strains use a highly similar virulence strategy to colonize tomato plants.

173 Plant signal-dependent regulation across hosts and pathotypes: growth in CPG vs.174 plants

- To pinpoint genes whose expression is modulated by the interaction with plants, samples extracted from tomato, banana and melon plants were compared with corresponding samples extracted from CPG medium. Because BMM medium appears to at least partially mimic the plant environment [18, 19], CPG medium appeared best suited to serve as a neutral baseline for comparison with plant samples. The detailed results are available in **Additional file 2**.
- A total of 1071 genes were differentially regulated by plant signals in at least one comparison.
 These genes were classified into 3 categories in an attempt to properly describe the influence
 of each plant x strain combination on the transcriptomic landscape (Fig. 2).
- 183 **Category 1.** A total of 123 genes were differentially expressed in all the plant x strain 184 combinations, and the majority of these genes followed a similar pattern of expression. 185 Twenty-two genes exhibited lower expression in plants in both strains, and most were related 186 to amino acid transport and metabolism according to COG predictions, including the gcv 187 (glycine catabolism) and dpp (dipeptide uptake) operons. Eighty genes showed higher 188 expression in plants, and functions related to energy production or carbohydrate transport and 189 metabolism were highly represented, including the cox (cytochrome C oxidase) and scr 190 operons [sucrose uptake and catabolism, contributing to virulence [3]]. More importantly, this 191 category includes 10 of the 69 T3Es shared by these two strains (e.g., *ripAM*, *ripAT*, *ripAY*, 192 *ripG3*, *ripR*, *ripC1*, *ripM*, *ripA5*, *ripAN*, and *ripAU*). Interestingly, 4 of these T3Es are part of 193 the core effectome (Ailloud et al., 2015, submitted). Moreover, RipAN is one of the rare 194 genes with non-synonymous polymorphisms that is conserved in all sequenced Moko and 195 NPB lineages. Although these genes are differentially expressed in all conditions and do not 196 diverge across strains and hosts, they provide important information about which genes are 197 modulated by plant signals in these *R. solanacearum* lineages.



Figure 2 – Venn diagram of differentially expressed genes *in planta* compared to rich medium. Numbers displayed in circles correspond to biologically relevant categories defined in the text.

198 Nonetheless, few genes showed divergent expression patterns across strains and plants. 199 Compared with CPG, 17 genes were up-regulated in the NPB strain in melon plants and in 200 both strains in tomato plants but were down-regulated in the Moko strain in banana plants. 201 Notable among these 17 genes was the *cco* operon (cytochrome C oxidase cbb-3 type), which 202 is involved in microaerobic energy metabolism [20] and virulence in tomato plants [21], and 203 the anaerobic ribonucleotide reductase genes (nrdD and nrdG), which are involved in strict 204 anaerobic growth. Structural differences between tomato or melon stems and banana stems, 205 commonly referred to as pseudostems, could explain the Moko-strain-specific expression 206 patterns observed during banana infection.

Category 2a. A total of 120 genes were differentially expressed only in the Moko strain in both tomato and banana plants. The gene encoding the endoglucanase *egl*, which is related to cell wall degradation, was only overexpressed in Moko strains. Only one T3E, *ripG5*, was upregulated in the Moko strain in both tomato and banana plants. This effector is part of the core effectome and belongs to the GALA family, which contributes to adaptation to different hosts [22].

213 Category 2b. A total of 162 genes were differentially expressed only in the NPB strain in 214 both tomato and melon plants. T3SS components, regulators and 31 T3Es were up-regulated 215 in the NPB strains in both tomato and melon plants (ripZ, ripAC, ripY, ripF1, ripH1, ripG6, 216 ripAO, ripG7, ripD, ripAJ, ripO, ripAR, ripP1, ripP2, ripE2, ripN, ripL, ripAP, ripBH, ripAE, 217 ripX, ripAB, ripH2, ripBC, ripH2 2, ripAX1, ripAQ, ripV2, ripBD, ripAW, and 218 RS T3E Hyp1). Remarkably, some of these effectors (e.g., ripV2, ripAO) were not present in 219 the IIB4 Moko strains but are widespread throughout the RSSC and in different Moko 220 lineages, indicating that they were most likely lost by the IIB4 Moko lineage.

221 These missing genes represent a major, yet somewhat unexpected, difference in type III 222 system regulation. Although experimental error cannot be excluded given the number of 223 parameters involved, these results nevertheless appear to be quite robust. The T3Es that were 224 found to be exclusively up-regulated in planta for the NPB strains (category 2b) were 225 classified as such according to a stringent logFC threshold of ± 2 , which corresponds to a 4-226 fold change in expression between conditions. In Moko strains, these T3Es were also more 227 expressed in plants than in CPG medium, albeit with a lower fold change. Biologically, this 228 result should be interpreted as a much greater plant-induced expression of some type III genes 229 in the NPB strain rather than as a lack of induction in the Moko strain.

Category 3a. Surprisingly, there were only 7 genes that were specifically differentially
expressed in tomato plants for both the Moko and NPB strains, including the *czcAB* genes,
which are involved in heavy metal resistance, which were up-regulated *in planta*.

Category 3b. A total of 177 genes were differentially expressed exclusively in the Moko strain during the colonization of banana plants. However, this interaction did not specifically modulate any T3Es or major metabolic operons. Several neighbor genes with putative functions related to siderophores and fur, the ferric uptake regulator, were up-regulated in banana plants.

Category 3c. In total, 99 genes were differentially expressed only in the NPB strain during
the colonization of melon plants. Specifically, the T3E *ripTPS* was down-regulated *in planta*,
whereas the T3E *ripI* was up-regulated.

241 Overall, the differential expression arising from plant interactions appears to be more strongly associated with strains rather than with hosts. These results suggest that differences in host 242 243 range between the Moko and NPB strains are not due to specific molecular adaptations to a 244 given host but rather a reshaping of the strain expression profile to be compatible with 245 different hosts. Among the numerous virulence factors characterized in R. solanacearum, 246 expression of T3SS and T3E genes appears to be differentially triggered in the Moko and 247 NPB strains upon plant cell contact. Recent studies [2, 3, 23] investigating T3SS regulation 248 have raised concerns regarding the established model; it is therefore difficult to draw 249 definitive conclusions as to the functional consequences of these results, particularly 250 considering that this analysis utilized pathotypes that are poorly characterized relative to the 251 model strain GMI1000.

252 Host-specific differential gene expression: plant vs. plant comparisons

253 Plant samples were compared across hosts and across strains. To assess intra-strain variations, 254 Moko and NPB tomato samples were compared with corresponding banana and melon 255 samples, respectively. For the Moko strain, 202 genes were differentially expressed between 256 tomato and banana. For the NPB strain, 95 genes were differentially expressed between 257 tomato and melon. Next, to assess inter-strain variation, the tomato samples were compared 258 with one another, and the banana sample was compared with the melon sample. In the tomato 259 samples, 118 genes were differentially expressed between the Moko and NPB strains. When 260 comparing banana and melon, 305 genes were found to be differentially expressed between 261 the Moko and NPB strains. These results were then cross-referenced to identify candidate 262 genes.

263 As expected, some genes that were previously identified as being differentially expressed 264 between the Moko and NPB strains under similar growth conditions (CPG, BMM and tomato plants) were expressed in a similar fashion when comparing the expression profiles of these 265 266 strains in banana and melon plants. The hexuronate transporter gene ExuT2 was up-regulated 267 in the Moko strain in banana plants compared with the NPB strain in melon plants. In the 268 NPB strain, this gene was also down-regulated in melon plants compared with tomato plants. 269 These patterns suggest that the function of ExuT2 is beneficial to fitness in banana but could 270 be detrimental in melon. Similarly, the catalase KatB gene was up-regulated in melon plants 271 compared with banana plants. However, this gene was not down-regulated in the Moko strain 272 in banana plants compared with tomato plants. Although the roles of these two genes in 273 virulence are not clearly defined, they were among the most differentially expressed genes 274 between the Moko and NPB strains under all the conditions tested, with a logFC of up to 6, 275 corresponding to a ~65-fold change.

276 In the Moko strain, the ferric uptake regulator fur, as well as numerous genes related to 277 siderophore biosynthesis, were up-regulated in banana plants compared with tomato and 278 melon plants. Considering that these same genes were also up-regulated exclusively in banana 279 plants compared with rich medium (category 2a), it appears that they are specifically induced 280 by the banana environment and may contribute to the fitness of the bacteria in this condition. 281 Iron-scavenging by R. solanacearum has been investigated to some degree, and siderophores 282 have been shown to not contribute to pathogenicity in tomato plants [24]. However, tomato 283 xylem is not iron limiting, and transgenic tomato plants that display iron-binding activity 284 exhibit increased resistance to R. solanacearum, suggesting that iron availability could be a 285 determining factor for virulence. Moreover, some plant pathogenic species of the Erwinia 286 family do require siderophore production to exhibit a complete pathogenic phenotype [25, 287 26]. Further investigation of the iron content in banana xylem sap, as well as the regulation of 288 ferric uptake in Moko and NPB strains, would help determine whether siderophores 289 contribute to pathogenicity in banana plants and to the host range of these two strains.

In the NPB strain, genes encoding the T3SS regulators HrpX and HrpY and nine T3Es (RipO1, **RipP1**, RipC2, **RipY**, RipS4, **RipE2**, **RipX**, **RipAB**, and **RipAC**) were up-regulated in melon plants compared with banana plants. The expression profiles of RipP1, RipY, RipE2, RipX, RipAB, and RipAC were expected, because these genes were also up-regulated exclusively in this strain compared with rich medium (category 2b). However, these effectors did not display any intra-strain variation. They are thus only induced by plant signals in the NPB strain and are not influenced by differences between the tomato and melon 297 environments. In the Moko strain, RipO1 and RipAB were down-regulated in banana plants 298 compared with tomato plants; their expression in the Moko strain might thus be detrimental to 299 bacterial fitness in banana plants. RipC2 was the only effector that was also up-regulated in 300 the NPB strain compared with the Moko strain in tomato plants. RipAX, RipAB and RipAC 301 are encoded by an HrpB-activated operon (formerly referred as PopABC) and are not required 302 for pathogenicity towards tomato or HR on tobacco. Moreover, RipAB and RipAC belong to 303 the core effectome. PopP1 is a member of the YopJ/AvrBsT family and has been shown to act 304 as an avirulence factor by stopping the GMI1000 strain from being pathogenic toward 305 Petunia cultivars and Arabidopsis thaliana [27]. The functions of the other T3Es, as well as 306 their roles in virulence, remain to be determined.

307 Finally, the Moko and NPB strains appeared to favor distinct nitrogen metabolic pathways in 308 banana and melon plants. A nitrite reductase encoded by the *nirBD* gene and a nitrate uptake 309 transporter encoded by narK3 are part of the nitrate assimilation pathway and are up-310 regulated in banana plants compared with melon plants. R. solanacearum is known to 311 scavenge nitrate from the xylem sap, and nitrate assimilation has been shown to contribute to 312 the development of early-stage infection [28]. Conversely, the genes *narHIJGKL*, *aniA*, *norB*, 313 and *hmp* were up-regulated in melon plants compared with banana plants. In the Moko strain, 314 these genes were also down-regulated in banana plants compared with tomato plants. These 315 genes encode enzymatic subunits or regulators and can induce partial denitrification (up to 316 nitrous oxide) and partial nitric oxide detoxification. These functions contribute to both 317 virulence and growth in xylem sap (Dalsing et al. 2015, submitted). The advantages conferred 318 by favoring either of these pathways remain to be determined, but these results suggest that 319 the banana xylem environment might require metabolic adaptation from the bacteria to 320 achieve colonization.

321 Conclusions

322 Contrary to our previous comparative genomics results, Moko and NPB strains from the IIB 323 lineage appear to exhibit far more divergent transcriptomics profiles than are suggested by 324 their gene content. Gene expression is generally convergent between pathotypes in similar 325 environmental conditions, but divergences are evident in distinct hosts. In banana plants, the 326 Moko strain tended to favor siderophore biosynthesis and nitrate assimilation, whereas the 327 NPB strain appeared to favor T3E expression and partial denitrification in melon plants. 328 Nevertheless, the differences in gene expression upon plant cell contact appear to be more 329 pathotype-specific than host-specific, particularly with respect to virulence-related genes.

- 330 Future functional studies should address the degree to which the differential expression of
- 331 T3Es, siderophores and nitrogen metabolic pathways are involved in the host range variations
- 332 observed between Moko and NPB strains.

333 Author contributions

The above work resulted from collaboration between all authors, and each author participated sufficiently in the work to take public responsibility for the content. PP and FA defined the research theme. FA, TL and PP performed the experiments. FA carried out the bioinformatics analysis. FA and PP drafted the article, and CA and TL participated in revising it critically for intellectual content. Each author gave final approval of the version of the manuscript to be published.

340 Competing interest Section

341 The authors declare that they have no competing interests.

342 Acknowledgements

343 The European Union (ERDF), Conseil Régional de La Réunion, the French Agence Nationale

- de la Recherche and CIRAD provided financial support. ANSES secured part of the doctoral
- fellowship awarded to F. Ailloud (contract Number 11-237/BSL).

346 Figures

- **Figure 1 Differential expression across all tested comparison.**
- 348 Grey bars indicate the total number of differentially expressed genes in the comparison. Blue 349 bars indicate the number of genes more expressed in the first condition while orange bars 350 indicate the number of genes more expressed in the second condition.
- Figure 2 Venn diagram of differentially expressed genes in planta compared to rich
 medium. Numbers displayed in circles correspond to biologically relevant categories defined
- 353 in the text

354 Additional files

- Additional file 1 Differentially expressed genes in each tested comparison (merged from edgeR and DEseq2 results and filtered with $-2 > \log FC > 2$ and FDR < 0.01
- 357 Additional file 2 Classification of differentially expressed genes according to criteria 358 described in text. In the first sheet, on each line, "CONV", "DIV", "ODD" describes the

- 359 expression pattern of the gene between Moko and NPB in similar conditions: conserved,
- 360 divergent and inconsistent, respectively. "Plant", "Moko", "NPB", "Tom.", "Mel." and
- 361 "Ban." corresponds to *in planta* expression categories 1, 2a, 2b, 3a, 3b, 3c, respectively.

362 **References**

- Genin S, Denny TP: Pathogenomics of the *Ralstonia solanacearum* species
 complex. Annual review of phytopathology 2012, 50:67-89.
- 365 2. Monteiro F, Genin S, van Dijk I, Valls M: A luminescent reporter evidences active
 366 expression of *Ralstonia solanacearum* type III secretion system genes throughout
 367 plant infection. *Microbiology* 2012, 158(Pt 8):2107-2116.
- 368 3. Jacobs JM, Babujee L, Meng F, Milling A, Allen C: The in planta transcriptome of
 369 *Ralstonia solanacearum*: conserved physiological and virulence strategies during
 370 bacterial wilt of tomato. *MBio* 2012, 3(4).
- Cellier G, Prior P: Deciphering phenotypic diversity of Ralstonia solanacearum
 strains pathogenic to potato. *Phytopathology* 2010, 100(11):1250-1261.
- 373 5. Wicker E, Grassart L, Coranson-Beaudu R, Mian D, Guilbaud C, Fegan M, Prior P:
 374 Ralstonia solanacearum strains from Martinique (French West Indies) exhibiting
 375 a new pathogenic potential. *Appl Environ Microbiol* 2007, **73**(21):6790-6801.
- Wicker E, Coranson-Beaudu R, Cadasse S, William MA: Emerging strains of
 Ralstonia solanacearum in the French West Indies raise new challenges to tomato
 breeders. Acta Horticulturae 2009(808):279-286.
- Boucher CA, Barberis P, Trigalet AP, Demery DA: Transposon mutagenesis of
 Pseudomonas solanacearum: isolation of Tn5-induced avirulent mutants. Journal
 of General Microbiology 1985, 131:2449-2457.
- Hendrick CA, Sequeira L: Lipopolysaccharide-Defective Mutants of the Wilt
 Pathogen Pseudomonas solanacearum. Appl Environ Microbiol 1984, 48(1):94-101.
- 384 9. Bolger AM, Lohse M, Usadel B: Trimmomatic: a flexible trimmer for Illumina
 385 sequence data. *Bioinformatics* 2014, 30(15):2114-2120.
- 38610.Langdon WB: Performance of genetic programming optimised Bowtie2 on
genome comparison and analytic testing (GCAT) benchmarks. BioData mining
2015, 8(1):1.
- 389 11. Quinlan AR: BEDTools: The Swiss-Army Tool for Genome Feature Analysis.
 390 Current protocols in bioinformatics / editoral board, Andreas D Baxevanis [et al]
 391 2014, 47:11 12 11-11 12 34.
- Robinson MD, McCarthy DJ, Smyth GK: edgeR: a Bioconductor package for
 differential expression analysis of digital gene expression data. *Bioinformatics* 2010, 26(1):139-140.
- 395 13. Love MI, Huber W, Anders S: Moderated estimation of fold change and dispersion
 396 for RNA-seq data with DESeq2. *Genome biology* 2014, 15(12):550.
- Anders S, McCarthy DJ, Chen Y, Okoniewski M, Smyth GK, Huber W, Robinson
 MD: Count-based differential expression analysis of RNA sequencing data using
 R and Bioconductor. *Nature protocols* 2013, 8(9):1765-1786.
- 400 15. Guo Y, Li CI, Ye F, Shyr Y: Evaluation of read count based RNAseq analysis
 401 methods. BMC genomics 2013, 14 Suppl 8:S2.
- 402 16. Flores-Cruz Z, Allen C: *Ralstonia solanacearum* encounters an oxidative
 403 environment during tomato infection. *Molecular plant-microbe interactions* :
 404 *MPMI* 2009, 22(7):773-782.

- 405 17. Gonzalez ET, Allen C: Characterization of a *Ralstonia solanacearum* operon 406 required for polygalacturonate degradation and uptake of galacturonic acid. 407 *Molecular plant-microbe interactions : MPMI* 2003, 16(6):536-544.
- Rahme LG, Mindrinos MN, Panopoulos NJ: Plant and environmental sensory
 signals control the expression of hrp genes in Pseudomonas syringae pv.
 phaseolicola. Journal of bacteriology 1992, 174(11):3499-3507.
- 411 19. Tang X, Xiao Y, Zhou JM: Regulation of the type III secretion system in phytopathogenic bacteria. Molecular plant-microbe interactions : MPMI 2006, 413 19(11):1159-1166.
- 414 20. Pitcher RS, Watmough NJ: The bacterial cytochrome cbb3 oxidases. *Biochimica et biophysica acta* 2004, 1655(1-3):388-399.
- 416 21. Colburn-Clifford J, Allen C: A cbb(3)-type cytochrome C oxidase contributes to
 417 *Ralstonia solanacearum* R3bv2 growth in microaerobic environments and to
 418 bacterial wilt disease development in tomato. Molecular plant-microbe interactions
 419 : MPMI 2010, 23(8):1042-1052.
- Remigi P, Anisimova M, Guidot A, Genin S, Peeters N: Functional diversification of
 the GALA type III effector family contributes to Ralstonia solanacearum
 adaptation on different plant hosts. New Phytol 2011, 192(4):976-987.
- 423 23. Zuluaga AP, Puigvert M, Valls M: Novel plant inputs influencing Ralstonia
 424 solanacearum during infection. Frontiers in microbiology 2013, 4:349.
- 425 24. Bhatt G, Denny TP: *Ralstonia solanacearum* iron scavenging by the siderophore
 426 staphyloferrin B Is controlled by *PhcA*, the global virulence regulator. *Journal of*427 *bacteriology* 2004, 186(23):7896-7904.
- 428 25. Dellagi A, Brisset MN, Paulin JP, Expert D: Dual role of desferrioxamine in
 429 Erwinia amylovora pathogenicity. Molecular plant-microbe interactions : MPMI
 430 1998, 11(8):734-742.
- 431 26. Expert D: WITHHOLDING AND EXCHANGING IRON: Interactions Between
 432 Erwinia spp. and Their Plant Hosts. Annual review of phytopathology 1999,
 433 37:307-334.
- 434 27. Lavie M, Shillington E, Eguiluz C, Grimsley N, Boucher C: PopP1, a new member
 435 of the YopJ/AvrRxv family of type III effector proteins, acts as a host-specificity
 436 factor and modulates aggressiveness of Ralstonia solanacearum. Molecular plant437 microbe interactions : MPMI 2002, 15(10):1058-1068.
- 438 28. Dalsing BL, Allen C: Nitrate assimilation contributes to *Ralstonia solanacearum*439 root attachment, stem colonization, and virulence. *Journal of bacteriology* 2014,
 440 196(5):949-960.
- 441

442

Conclusion

Les données présentées et analysées dans cette étude représentent une approche originale abordant la question de la variation du spectre d'hôte chez *R. solanacearum* grâce des techniques modernes. Principalement exploratoires, ces travaux constituent la première analyse globale du transcriptome de *R. solanacearum* par séquençage (RNAseq), ainsi que la première analyse de l'expression génique de la lignée IIB-4, des écotypes Moko et NPB et de la colonisation du bananier ou du melon. Globalement, ces données permettent de décrire l'étendue des différences d'expression pouvant exister au plan de l'induction par le contact avec les plantes, de la colonisation d'un hôte commun ou d'hôtes distincts, au sein d'une même souche ou de souches d'écotypes distincts Moko et NPB.

Les différences d'expression les plus importantes ont été observées lors de la comparaison des conditions de culture *in vitro*, entre un milieu riche et un milieu minimum. Des différences bien plus faibles caractérisent les comparaisons entre hôtes végétaux, suggérant une similarité relative entre les environnements vasculaires des plantes. En moyenne, les comparaisons des échantillons plantes avec le milieu minimum pointent moins de gènes différentiellement exprimés que les comparaisons avec le milieu riche, ce qui est cohérent avec le fait que le xylème soit apparenté a un milieu de croissance pauvre pour les bactéries (Pegg, 1985).

Les transcriptomes des souches Moko et NPB de la lignée IIB-4 sont significativement divergents, notamment lors de l'infection d'hôtes exclusifs à leur gamme d'hôte respective : le bananier et le melon. En accord avec notre hypothèse de départ, les différences génomiques précédemment observées entre les deux écotypes semblent se traduire par des différences d'expressions de gènes associés au flétrissement bactérien. Certains effecteurs de type III présentent des différences constitutives d'expression entre les écotypes Moko et NPB notamment au niveau de l'induction par la plante mais aussi durant la colonisation du bananier et du melon. Le manque de données fonctionnelles quant aux rôles et aux cibles de ces effecteurs
ne permet cependant pas d'émettre d'hypothèse sur leur implication dans la variation du spectre d'hôte.

Il a été identifié parmi les gènes les plus différentiellement exprimés entre Moko et NPB et entre toutes les conditions : *exuT2*, un homologue du gène *exuT* codant pour un transporteur d'hexuronate (Gonzalez and Allen, 2003), un produit de la dégradation enzymatique de la paroi végétale ; et *katB*, un gène codant pour une catalase impliquée dans la réponse au stress oxydatif (Flores-Cruz and Allen, 2009). Le gène *exuT2* est 65 fois plus exprimé chez la souche Moko que chez la souche NPB et vice versa pour le gène *katB*. Bien qu'il soit difficile de prédire l'implication directe de ces gènes présentant une forte expression différentielle dans la virulence, il est tout de même très probable qu'ils contribuent au fitness de la bactérie lors de la colonisation. Des gènes présentant une expression différentielle plus faible sont probablement aussi impliqués dans la variation du spectre d'hôte et nécessiteront d'analyser ces données RNAseq de manière plus fine. En effet, les analyses présentées ont été réalisées avec une limite de 4-fold afin d'identifier les différences les plus flagrantes. Dans la littérature, une limite de 2-fold est souvent considérée comme acceptable pour observer des différences biologiquement significatives.

La description de ces données transcriptomiques n'est donc pas encore exhaustive et nécessitera des analyses plus fines afin d'identifier toutes les différences caractérisant les souches Moko et NPB. Les résultats les plus significatifs pourront être confirmés par des méthodes alternatives comme la PCR quantitative et les gènes candidats explorés fonctionnellement par mutagénèse, afin de déterminer si ils sont le moteur ou seulement la conséquence de la variation du spectre d'hôte.

Conclusion générale et perspectives

Les différents travaux entrepris au cours de ma thèse ont été conduits autour d'une thématique commune : la caractérisation des divergences au sein du complexe d'espèces à partir de données génomiques. En effet, malgré les problèmes inhérents au séquençage de 2^{nde} génération, le séquençage d'une dizaine de génomes de souches du phylotype II a constitué le socle de la réorganisation taxonomique du RSSC, du développement d'un outil diagnostic et de l'analyse des caractères génomiques et transcriptomiques propres à certains écotypes.

La réévaluation taxonomique de *R. solanacearum* fut suggérée depuis les années 70 suite à la caractérisation du phylotype IV ayant amenée à la désignation de complexe d'espèces (RSSC). Paradoxalement, le phylotype IV fut le dernier à être séquencé parmi les quatre phylotypes existants, et l'étude des génomes de chaque espèce le composant – R. solanacearum, BDB et R. syzygii – démontra définitivement qu'il n'était composé que d'une seule et même espèce (Remenant et al., 2011) confirmant ainsi la légitimité d'une évolution taxonomique du RSSC vers un modèle à trois espèces à l'aide de distances génomiques obtenues in silico (ANI) : les phylotypes II et IV formeraient chacun une espèce distincte tandis que les phylotype I et III sont élevés au rang de la même espèce [Cette proposition fut par ailleurs poursuivie indépendamment par la communauté à l'aide de techniques complémentaires]. Une équipe Australienne valida indépendamment le schéma à trois espèces avec les méthodes utilisées historiquement en taxonomie consistant en des expériences d'hybridation ADN-ADN et des analyses biochimiques (Safni et al., 2014). Dans le cadre de ma thèse, j'ai exploré la taxonomie de R. solanacearum à l'aide de plusieurs algorithmes de distances génomiques (ANI, MUMi et GGDC) appliqués à 29 génomes. Cette approche a été renforcée par une analyse protéomique portant sur la caractérisation de 74 souches par spectrométrie de masse (MALDI-TOF), puis par des analyses phénotypiques portant sur la dénitrification. Bien que les données phénotypiques disponibles actuellement ne supportent qu'un schéma à trois espèces, les distances génétiques calculées par les algorithmes les plus récents (MUMi et GGDC) suggèrent que la division du RSSC pourrait théoriquement aller jusqu'à cinq espèces distinctes en se basant sur des distances génomiques seuils, qui corrèlent avec la DDH. Ceci renforce l'idée d'une grande hétérogénéité dans le complexe d'espèce, et que la diversité génétique réelle chez *R. solanacearum* est bien plus élevée que celle suggérée par le schéma taxonomique en place actuellement. De plus, nos données concernant la dénitrification étaient en contradiction avec celles du laboratoire Australien. La répétition des analyses ainsi que l'association du phénotype aux voies métaboliques identifiées dans les génomes étudiés ont confirmé la validité de nos données, tout en illustrant l'importance d'intégrer des séquences génomiques dans la démarche taxonomique globale. La classification proposée est la suivante :

- Ralstonia solanacearum (phylotype II)
- Ralstonia pseudosolanacearum sp. nov. (phylotype I et III)
- *Ralstonia syzygii* sp. nov. (phylotype IV)
 - Sous-espèce *indonesiensis* subsp. nov. (*R. solanacearum* phylotype IV)
 - Sous-espèce *celebesensis* subsp. nov. (BDB)
 - Sous-espèce *syzygii* subsp. nov. (*R. syzygii*)

En décrivant formellement les différences fondamentales existant au sein du RSSC sous la forme de nouvelles espèces, cela permettra entre-autres de dynamiser la recherche fondamentale (choix des modèles d'études), de faciliter la recherche appliquée en diagnostic, en épidémiologie et surtout en sélection pour la résistance variétale.

Les pathotypes n'ont absolument aucune valeur de taxon même pour des germes monomorphes et donc ne sont d'aucune utilité pour la délimitation de nouvelles espèces. Néanmoins, certaines lignées phylogénétiques de *R. solanacearum* sont facilement distinguables grâce à leur spectre d'hôte. Adaptées à certaines espèces végétales, ces lignées sont ainsi considérées comme des écotypes par la communauté des phytobactériologistes. Ces écotypes sont retrouvés chez le phylotype IV incluant les souches BDB, restreintes au bananier, et les souches *R. syzygii*, restreintes au giroflier. Ils sont aussi présent chez le phylotype II incluant les souches Brown rot, infectant la pomme de terre à basse température, les souches Moko adaptées au bananier, et les souches NPB adaptées aux Cucurbitacée. Dans le cadre de mes travaux de génomique comparative, les écotypes du phylotype II ont été choisis comme modèle d'étude car ils sont proches d'un point de vue génétique et phénotypique tout en étant nettement différentiables. En effet, les trois écotypes Moko, Brown rot et NPB sont tous pathogènes de la tomate, mais sont chacun adaptés à un hôte spécifique. De plus, l'écotype Moko est polyphylétique, certaines lignées Moko du phylotype IIB sont ainsi génétiquement proches des lignées Brown rot et NPB, alors que d'autres sont relativement plus distantes (IIA). Par ailleurs, les souches du phylotype II sont généralement plus disponibles dans les collections locales et internationales et représentent de meilleurs pathosystèmes eu égard à la possibilité d'étudier leur pouvoir pathogène en conditions artificielles, facilitant la caractérisation fonctionnelle de gènes candidats in planta. Compte tenu de ces caractéristiques uniques au sein du RSSC, nous avons formulé l'hypothèse que la comparaison directe de ces écotypes permettrait d'identifier des caractères génomiques contribuant à expliquer la variation du spectre d'hôte. D'un point de vue quantitatif, peu de différences génétiques entre les écotypes étaient cependant attendues. En effet, les phylogénies *egl* ou MLST décrivaient déjà les écotypes du phylotype II comme très proches à l'échelle du RSSC ; la comparaison génomique d'une souche Moko IIB-3 et d'une souche Brown rot IIB-1 avait également permis d'observer une grande similarité. Durant cette thèse, la phylogénie basée sur la comparaison de génomes complets a confirmé la proximité génétique globale des écotypes du phylotype II, notamment des lignées Moko et NPB non séquencées auparavant.

Les nouveaux génomes que nous avons produits ont servi dans un premier temps à redéfinir le core-génome du RSSC et par conséquent à identifier les facteurs de virulence conservés chez toutes ces souches, notamment les T3E. Parmi le répertoire de 113 T3E observé au sein des 19 génomes analysés, seuls 14 effecteurs sont conservés dans tous les génomes. Comparé à d'autres bactéries phytopathogènes possédant un T3SS, le core-effectome de *R. solanacearum* apparaît donc minimal et illustre ainsi la forte plasticité génétique de l'espèce. Ces effecteurs ont probablement un rôle central dans l'établissement du flétrissement bactérien et leur caractérisation fonctionnelle permettra de mieux concevoir les mécanismes fondamentaux mis en jeu lors de l'infection. L'étude des T3E non-conservés du répertoire sera néanmoins requise pour expliquer pourquoi autant d'effecteurs existent à l'échelle du RSSC, quand si peu semblent indispensables au pouvoir pathogène. Paradoxalement, la délétion d'un seul effecteur ne provoque que rarement une faible modification observable du phénotype virulent, mais la délétion du système de sécrétion en lui-même s'accompagne de la perte de la virulence.

La génomique comparative des écotypes retenus dans nos travaux a été effectuée à plusieurs niveaux en faisant appel à un large panel d'outils bioinformatiques. Les génomes des différentes lignées Moko ont été successivement comparés pair-à-pair aux génomes Brown rot, puis NPB. Cette comparaison paire-àpaire des écotypes permet de concentrer l'analyse sur des souches possédant des fonds génétiques adaptés à des hôtes très spécifiques à l'échelle du RSSC. Il est probable que les phénotypes observés chez les écotypes soient le résultat d'une combinaison de plusieurs facteurs génétiques. La distribution des gènes est mosaïque au sein du RSSC, dû à la forte diversité génétique du RSSC et à la capacité naturelle chez *R. solanacearum* d'acquérir des gènes par transfert horizontal. Certains gènes contribuant partiellement à la virulence chez ces écotypes pourraient ainsi avoir été conservés ou transférés chez d'autres lignées. Ces dernières, ne possédant pas le même fond génétique que les écotypes, ne sont néanmoins pas capables de restituer un phénotype identique. De plus, la structure phylogénétique du phylotype II suggère que les Brown rot et NPB ont émergé a partir des lignées IIB-3 et IIB-4 respectivement, et donc potentiellement à partir d'un fond génétique de « type » Moko. Les comparaisons paire-à-paire permettent ainsi d'identifier précisément l'évolution de ce fond génétique. Les gènes acquis ou perdus au sein de chaque écotype ont été identifiés en observant le contenu en gène spécifique à chaque groupe et les polymorphismes protéiques conservés ont été criblés chez les gènes partagés par plusieurs écotypes. Enfin, une analyse de réconciliation phylogénétique a déterminé d'une part les gains et pertes de gènes chez chaque lignée et, d'autre part, les transferts horizontaux au sein du RSSC, notamment entre lignées Moko.

Ces multiples analyses ont permis d'identifier principalement des traits spécifiques de chaque écotype et, par conséquent, potentiellement impliqués dans la variation du spectre d'hôte. La caractérisation des transferts horizontaux a servi également à tester plusieurs hypothèses concernant l'origine polyphylétique des souches Moko : i) dispersion verticale du phénotype à partir d'un ancêtre commun à toutes les lignées Moko actuelles ii) propagation du phénotype par transfert horizontal à partir d'une des lignées Moko actuelles. Les résultats obtenus n'ont cependant pas permis de conclure définitivement sur une hypothèse en particulier. L'utilisation d'algorithmes plus sensibles pour détecter les transferts horizontaux, mais principalement une meilleure compréhension des mécanismes mis en jeu dans la virulence sur bananier, permettraient d'appréhender plus efficacement l'apparition et l'évolution de ce phénotype au sein du RSSC, notamment vis-à-vis des souches BDB du phylotype IV qui sont relativement éloignées en terme de distance phylogénétique.

Bien que ces analyses n'aient révélées qu'un faible nombre global de gènes et de polymorphismes spécifiques des écotypes, elles ont permis d'identifier de nombreux effecteurs de type III polymorphiques ou spécifiques d'un écotype. Les analyses fonctionnelles préliminaires sont encourageantes et la délétion de *ripAA* (plus connu sous la dénomination *avrA*, un T3E perdu par les souches NPB mais présent dans toutes les lignées Moko) chez une souche IIB-4 Moko entraine une perte totale de virulence chez le bananier. Néanmoins, l'effecteur *ripAA* est très répandu dans le RSSC et il est présent chez des souches non pathogènes du bananier. De plus, il est également impliqué dans la modulation de la virulence chez différentes espèces de tabac. La mutagénèse des autres effecteurs identifiés par ces travaux pourrait donc permettre d'identifier des facteurs de virulence indispensables à la pathogénicité sur certains hôtes en fonction du fond génétique.

La compréhension fine du mécanisme d'action de ces effecteurs nécessitera cependant une caractérisation plus approfondie impliquant la cible ou le substrat, la localisation, la cinétique d'expression en fonction de l'hôte, du tissu végétal et de la densité cellulaire. Ces approches seront nécessaires pour déterminer quels sont précisément les processus biologiques impliqués dans la variation du spectre d'hôte. En effet, les effecteurs de type III sont génétiquement et fonctionnellement très variés (et parfois redondant) et leur sécrétion permet une interaction extrême avec l'hôte. De plus, ils représentent, à ce jour, la seule famille de gènes ayant été associés à la gamme d'hôte chez *R. solanacearum*. Les différentes fonctions assurées par les effecteurs de type III décrites dans la littérature suggèrent cependant qu'ils représentent une véritable trousse à outil moléculaire coopérant avec de multiples systèmes n'étant pas eux-mêmes reliés immédiatement à la virulence.

Chez *Salmonella typhymurium*, une entérobactérie pathogène, le burst oxydatif produit par les leucocytes au sein de la muqueuse de l'hôte, et induit par le T3SS, est responsable de l'inflammation intestinale et entraine en parallèle l'oxydation d'un compose soufré qui est ensuite utilisé comme accepteur terminal d'électron par le système respiratoire des bactéries présentes dans la lumière intestinale (Winter et al., 2010). La respiration permise par ce composé oxydé confère un avantage métabolique a *S. typhy* par rapport aux autres organismes de la flore intestinale et est ainsi directement dépendante de l'inflammation provoque par le T3SS.

Chez *Pseudomonas aeruginosa*, un pathogène opportuniste, le T3SS induit la formation de pores dans la membrane des macrophages et provoque alors une fuite de nutriments ainsi qu'une molécule chimio-attractante ayant pour conséquence l'accumulation des bactéries autour des macrophages (Dacheux et al., 2001). En amont, le T3SS semble définitivement être relié à l'état nutritionnel de la bactérie, car sa production a été associée au métabolisme du pyruvate (Dacheux et al., 2002), de l'histidine (Rietsch et al., 2004) et du tryptophane (Shen et al., 2008).

Tout comme les facteurs de virulence, le métabolisme d'un agent pathogène a besoin de s'adapter pour survivre au sein d'un hôte dont les conditions environnementales sont souvent très différentes de celles du réservoir bactérien. L'interdépendance du métabolisme avec un système aussi versatile que celui des effecteurs de type III apparaît donc comme un mécanisme permettant plus de flexibilité dans l'adaptation face à l'évolution des conditions environnementales. Dans le cas de *R. solanacearum*, la multiplicité des réservoirs (eau, sol, mauvaises herbes), des vecteurs (insectes dans le cas de *R. syzygii* subsp. *syzygii*) et surtout des hôtes sensibles a probablement entrainé une forte capacité d'adaptation du métabolisme de la bactérie. Bien que peu de données soient disponibles sur les différences de composition du xylème entre les végétaux concernés (mono et dicotylédones), il est possible qu'elles soient en partie responsables des variations du spectre d'hôte observées chez *R. solanacearum*, en sus des mécanismes de défense et des gènes de résistances de la plante. La compréhension du métabolisme de la plante en complément de celui la bactérie apparaît donc indispensable pour mieux appréhender l'adaptation à l'hôte.

Les résultats de l'analyse transcriptomique des souches IIB-4 Moko et NPB dans divers conditions environnementales, *in vitro* et *in planta*, ont mis en évidence des différences d'expression impliquant le T3SS, le métabolisme de l'azote et des systèmes putatifs d'acquisition du fer (sidérophores). En effet, cette approche a montré que la régulation transcriptionnelle de nombreux effecteurs diffère entre les écotypes Moko et NPB, ainsi qu'entre les différents fonds génétiques hôtes testés. Au contraire, les autres facteurs de virulence caractérisés chez R. solanacearum présentent très peu de différences d'expression dans les mêmes conditions, suggérant que les T3E sont potentiellement des déterminants majeurs de la spécificité d'hôte in planta. Outre leur complexité aux niveaux génomique et transcriptomique, les T3E pourraient également être modulés au niveau protéomique. En effet, il a été démontré que la sécrétion de certains effecteurs est contrôlée par une protéine chaperonne (incluant AvrA) (Lohou et al., 2014). En parallèle, des différences d'expression des voies métaboliques de l'azote et de l'acquisition du fer ont été observées entre des hôtes distincts (le bananier et le melon). Cependant, la corrélation entre les ressources nutritives existantes au sein de chaque hôte et les variations observées restent encore à prouver. De même, une

éventuelle coordination fonctionnelle entre les T3E et les voies métaboliques que nous avons pointées devra être approfondie. L'expression des voies métaboliques de l'azote est particulièrement remarquable de par son antinomie. En effet la voie d'assimilation et la voie de dénitrification ont une expression opposée chez les souches Moko et NPB lors de l'infection du bananier et du melon, respectivement. Ces deux voies utilisent le nitrate présent dans le milieu, la première le métabolise successivement en ammonium qui sera intégré par la suite dans des composés organiques azotés; tandis que la dernière l'utilise comme accepteur terminal d'électrons. Bien qu'elles remplissent des fonctions métaboliques radicalement différentes, ces voies contribuent chacune à la virulence (Dalsing and Allen, 2014) (Dalsing et al. 2015, *in press*). L'assimilation du nitrate est associée à l'attachement aux racines et à la production de l'EPS; la dénitrification permet également de détoxifier le monoxyde d'azote (NO) potentiellement produit par les défenses de la plante. Les variations d'expression pourraient donc aussi bien constituer une adaptation métabolique à l'environnement qu'une adaptation de la stratégie de virulence en réponses aux mécanismes de défenses de chaque hôte. Dans un contexte global, la dénitrification est aussi un processus qui nous a permis de définir plusieurs espèces au sein du RSSC, car seuls les phylotypes I et III sont capables d'effectuer complètement la voie aboutissant à la production de di-nitrogène. Par conséquent, la dénitrification a très probablement constitué un phénotype important dans l'évolution de *R. solanacearum*.

Mes travaux de thèse montrent que nos approches génomique et transcriptomique ont permis de caractériser des différences qualitatives et quantitatives associées à la variation du spectre d'hôte. Dans de futurs travaux, cette problématique pourra être analysée sous différents angles. Les analyses de protéomiques réalisées dans le cadre de cette thèse en vue de délimiter des espèces au sein des RSSC ont démontré que le protéome globale est assez discriminant pour distinguer chaque lignée par spectrométrie de masse. Plus particulièrement, les T3E réellement sécrétés par chaque écotype en fonction des hôtes infectés et le sécrétome en général pourraient être identifiés à haut débit à l'aide de techniques de spectrométrie de masse qui ne nécessitent pas de déterminer *a priori* les protéines dont on veut étudier la sécrétion; en comparaison des méthodes utilisant des protéines de fusions (Mukaihara and Tamura, 2009). Par exemple, les protéines surexprimées par les souches Brown rot exposées à de faibles températures ont déjà été caractérisées (Bocsanczy et al., 2014).

Les changements induits chez l'hôte lors de la colonisation sont aussi à prendre en compte et peuvent servir à déduire indirectement le fonctionnement métabolique de la bactérie et les enjeux majeurs de la virulence. Par exemple, la modification du contenu en acide aminés et en sucres au sein du xylème de la tomate au cours de l'infection a été déterminée par chromatographie à échange d'ions (Zuluaga et al., 2013).

Les hypothèses génomiques et transcriptomiques pourront également être approfondies au fur et à mesure des avancées technologiques. Le reséquencage avec des techniques de 3ème génération (PacBio) améliorerait grandement la qualité des génomes par rapport à la 2nde génération et permettrait par exemple de distinguer le chromosome du mégaplasmide, ouvrant la voie à l'étude de la dynamique évolutive des deux réplicons. Le séquençage des microARN et de la méthylation révèlerait des surcouches de régulations de l'expression encore inexplorées chez *R. solanacearum*, tandis qu'une analyse haut débit des interactions protéines/ADN identifierait, à l'échelle du génome, les régions cibles des éléments trans-régulateurs déjà caractérisés.

De manière générale, l'explosion des « omics » permet aujourd'hui d'envisager une caractérisation approfondie et haut-débit des multiples facettes de la spécificité d'hôte chez *R. solanacearum*. La stratégie et le choix du modèle expérimental restent cependant les plus importants afin d'obtenir des résultats correspondant à une réalité biologique.

La thématique centrale de ma thèse et les stratégies associées ont visé à caractériser des différences au sein du RSSC en se basant sur des souches

présentant une forte diversité aussi bien génétique que phénotype. Inversement, la diversité de ces souches peut être mise à profit en caractérisant les similarités entre ces dernières conformément à l'hypothèse « classique » que les traits génétiques ayant subsistés au cours du temps sont essentiels (i.e. core génome) pour maintenir, entre autres, le phénotype virulent. Dans un 2nd temps il est possible de tirer parti de la disponibilité exponentielle de génomes dans les bases de données en comparant dans un premier temps le core génome i) aux génomes de bactéries telluriques non phytopathogènes afin d'y soustraire, par exemple, les orthologues des voies métaboliques centrales ; puis successivement ii) aux génomes de phytopathogènes colonisant le xylème afin de cerner les gènes potentiellement impliqués dans la colonisation de ce compartiment végétal. Les gènes restants constitueraient ainsi le « patho-core-genome du flétrissement bactérien » (ou MWGS pour 'Minimal Wilt Gene Set') (**Figure 26**).

En dehors du modèle étudié lors de cette thèse, d'autres modèles intéressants (car complémentaires) existent au sein du RSSC. Le phylotype IV héberge des souches dont la gamme d'hôtes est restreinte à un unique représentant (bananier, giroflier) et divergente en fonction des lignées. Elles présentent, par exemple, une opportunité de réaliser des expériences d'évolution expérimentale visant à étendre la gamme d'hôte d'une souche *via* le transfert de facteurs de spécificité d'hôte candidats. L'accroissement de nos connaissances de la diversité génotypique et phénotypique chez *R. solanacearum* permettra probablement de mettre en évidence de nouveaux modèles permettant des approches originales.

Conceptuellement, quel que soit le modèle choisi, les approches de type Omics tendent à établir les bases génétiques associées à un caractère phénotypiques ('forward genetics'). La caractérisation fonctionnelle d'un trait phénotypique particulier nécessite cependant de (re)démontrer le phenotype produit par un trait génétique spécifique ('reverse genetics'). La transition est d'autant plus complexe quand des différences génétiques subtiles sont à l'origine de modification majeures du phénotype. Dans le cas spécifique de l'adaptation à l'hôte chez les phytopathogènes, il a été démontré chez deux espèces voisines d'oomycètes,



Figure 26 - Représentation schématique du Minimal Wilt Gene Set.

Phytophthora infestans et P. mirabilis, adaptées respectivement aux Solanées et aux plantes ornementales du genre *Mirabilis*, qu'un unique polymorphisme au sein d'un effecteur inhibiteur de protéase, identifié initialement par génomique comparative, est responsable de l'adaptation de son activité enzymatique aux protéases spécifiques de chaque espèce végétale (Dong et al., 2014). Chez *R. solanacearum*, des expériences d'évolution expérimentale couplées à du séquençage haut-débit ont permis d'identifier un nombre très limité de mutations acquises suite un gain de fitness chez un hôte distant (absence de flétrissement mais colonisation possible de la tige). La mutation de ces régions a néanmoins démontré par la suite qu'elles étaient effectivement associées au processus d'adaptation observé expérimentalement (Guidot et al., 2014). Dans le cadre de ma thèse, une collaboration avec T. Lowe (UW Madison, Allen's lab) a permis le rapprochement entre l'investigation fonctionnelle de la voie de dégradation des acides hydroxycinnamiques (HCAs) en relation avec la résistance aux défenses des plantes et la distribution génétique de cette voie au sein du complexe d'espèce ainsi que chez d'autres phytopathogènes (Lowe et al., 2015) (Annexe 2). Les évolutions futures de la rapidité de mise en œuvre, de l'efficacité et de la fiabilité des méthodes de mutagénèse permettront progressivement de coupler de plus en plus aisément des approches génétiques haut-débit forward et reverse a grande échelle et contribuera ainsi à une vue plus systématique (et intégrative) des questions de biologie que nous avons abordées.

La large gamme d'hôte de *R. solanacearum* représente une des caractéristiques distinguant cette bactérie des autres agents phytopathogènes. Paradoxalement, la plupart des souches étudiées sont rarement testées sur des hôtes autres que les plantes sur lesquelles elles ont été isolées. Un examen approfondie du spectre d'hôte du RSSC dans son ensemble pourrait pourtant permettre d'identifier d'autres écotypes et de déterminer s'il existe une corrélation entre tous les végétaux infectés par une même souche (famille végétale, composition ou structure des tissus, mécanismes de défenses). Un échantillonnage réfléchi de niches écologiques telles que les réservoirs naturels comme le sol, l'eau ou certains végétaux dans lesquels

l'organisme réside à l'état latent comme les innombrables mauvaises herbes (plantes adventices), contribuerait à la compréhension de l'évolution de ce pathogène (compartiments naturels vs. cultivés) grâce à l'identification de souches potentiellement moins aptes à produire du flétrissement. En effet, les collections de bactéries pathogènes sont fréquemment biaisées par le fait que les souches prélevées sont souvent celles ayant effectivement provoquée une infection et représentent par conséquent les génotypes les mieux adaptés à la virulence dans ces conditions environnementales. À leur tour, les souches les plus virulentes sont surreprésentées suite au « bottleneck » artificiel généré par la faible diversité des espèces végétales et des cultivars exploités par l'agriculture moderne.

Références bibliographiques

- Abecasis, G.R., Altshuler, D., Auton, A., Brooks, L.D., Durbin, R.M., Gibbs, R.A., Hurles, M.E., and McVean, G.A. 2010. A map of human genome variation from population-scale sequencing. Nature 467:1061-1073.
- Adams, M.D., Kelley, J.M., Gocayne, J.D., Dubnick, M., Polymeropoulos, M.H., Xiao, H., Merril, C.R., Wu, A., Olde, B., Moreno, R.F., and et al. 1991.
 Complementary DNA sequencing: expressed sequence tags and human genome project. Science 252:1651-1656.
- Adessi, C., Matton, G., Ayala, G., Turcatti, G., Mermod, J.J., Mayer, P., and Kawashima, E. 2000. Solid phase DNA amplification: characterisation of primer attachment and amplification mechanisms. Nucleic acids research 28:E87.
- Albuquerque, G.M., Santos, L.A., Felix, K.C., Rollemberg, C.L., Silva, A.M., Souza,
 E.B., Cellier, G., Prior, P., and Mariano, R.L. 2014. Moko Disease-Causing
 Strains of *Ralstonia solanacearum* from Brazil Extend Known Diversity in
 Paraphyletic Phylotype II. Phytopathology 104:1175-1182.
- Aldon, D., Brito, B., Boucher, C., and Genin, S. 2000. A bacterial sensor of plant cell contact controls the transcriptional induction of *Ralstonia solanacearum* pathogenicity genes. The EMBO journal 19:2304-2314.
- Allen, C., Gay, J., and Simon-Buela, L. 1997. A regulatory locus, pehSR, controls polygalacturonase production and other virulence functions in *Ralstonia solanacearum*. Molecular plant-microbe interactions : MPMI 10:1054-1064.
- Altenhoff, A.M., Schneider, A., Gonnet, G.H., and Dessimoz, C. 2011. OMA 2011: orthology inference among 1000 complete genomes. Nucleic acids research 39:D289-294.
- Alwine, J.C., Kemp, D.J., and Stark, G.R. 1977. Method for detection of specific RNAs in agarose gels by transfer to diazobenzyloxymethyl-paper and hybridization with DNA probes. Proceedings of the National Academy of Sciences of the United States of America 74:5350-5354.
- Angot, A., Peeters, N., Lechner, E., Vailleau, F., Baud, C., Gentzbittel, L., Sartorel, E., Genschik, P., Boucher, C., and Genin, S. 2006. *Ralstonia solanacearum* requires F-box-like domain-containing type III effectors to promote disease on several host plants. Proceedings of the National Academy of Sciences of the United States of America 103:14620-14625.
- Aragaki, M., and Quinon, V. 1965. Bacterial wilt of ornamental gingers (Hedychium spp.) caused by *Pseudomonas solanacearum*. Plant Dis. Rptr. 49:378-379.
- Arlat, M., Gough, C.L., Zischek, C., Barberis, P.A., Trigalet, A., and Boucher, C.A.
 1992. Transcriptional organization and expression of the large hrp gene cluster of *Pseudomonas solanacearum*. Molecular plant-microbe interactions : MPMI 5:187-193.

Astua-Monge, G., Freitas-Astua, J., Bacocina, G., Roncoletta, J., Carvalho, S.A., and Machado, M.A. 2005. Expression profiling of virulence and pathogenicity genes of *Xanthomonas axonopodis* pv. citri. J Bacteriol 187:1201-1205.

Auch, A.F., von Jan, M., Klenk, H.P., and Goker, M. 2010. Digital DNA-DNA hybridization for microbial species delineation by means of genome-togenome sequence comparison. Standards in genomic sciences 2:117-134.

Bernoux, M., Timmers, T., Jauneau, A., Briere, C., de Wit, P.J., Marco, Y., and Deslandes, L. 2008. RD19, an Arabidopsis cysteine protease required for RRS1-R-mediated resistance, is relocalized to the nucleus by the *Ralstonia solanacearum* PopP2 effector. Plant Cell 20:2252-2264.

Bocsanczy, A.M., Achenbach, U.C., Mangravita-Novo, A., Chow, M., and Norman, D.J. 2014. Proteomic comparison of *Ralstonia solanacearum* strains reveals temperature dependent virulence factors. BMC genomics 15:280.

Boucher, C.A., Gough, C.L., and Arlat, M. 1992. Molecular genetics of pathogenicity determinants of *Pseudmonas solanacearum* with special emphasis on *HRP* genes. Annual Review of Phytopathology 30:433-461.

Boucher, C.A., Barberis, P., Trigalet, A.P., and Demery, D.A. 1985. Transposon mutagenesis of *Pseudomonas solanacearum*: isolation of Tn5-induced avirulent mutants. Journal of General Microbiology 131:2449-2457.

Bozdech, Z., Zhu, J., Joachimiak, M.P., Cohen, F.E., Pulliam, B., and DeRisi, J.L. 2003. Expression profiling of the schizont and trophozoite stages of *Plasmodium falciparum* with a long-oligonucleotide microarray. Genome biology 4:R9.

Brenner, D., Staley, J., and Krieg, N. 2000a. Classification of prokaryotic organisms and the concept of Bacterial speciation. in: Bergey's manual of systematic bacteriology., Springer, New York, NY.

Brenner, S., Johnson, M., Bridgham, J., Golda, G., Lloyd, D.H., Johnson, D., Luo, S., McCurdy, S., Foy, M., Ewan, M., Roth, R., George, D., Eletr, S., Albrecht, G., Vermaas, E., Williams, S.R., Moon, K., Burcham, T., Pallas, M., DuBridge, R.B., Kirchner, J., Fearon, K., Mao, J., and Corcoran, K. 2000b. Gene expression analysis by massively parallel signature sequencing (MPSS) on microbead arrays. Nature biotechnology 18:630-634.

Brito, B., Marenda, M., Barberis, P., Boucher, C., and Genin, S. 1999. prhJ and hrpG, two new components of the plant signal-dependent regulatory cascade controlled by PrhA in *Ralstonia solanacearum*. Molecular microbiology 31:237-251.

Brown, D.G., and Allen, C. 2004. *Ralstonia solanacearum* genes induced during growth in tomato: an inside view of bacterial wilt. Molecular microbiology 53:1641-1660.

Brown, D.G., Swanson, J.K., and Allen, C. 2007. Two host-induced *Ralstonia solanacearum* genes, *acrA* and *dinF*, encode multidrug efflux pumps and contribute to bacterial wilt virulence. Applied and environmental microbiology 73:2777-2786.

Buddenhagen, I., Sequeira, L., and Kelman, A. 1962. Designation of races in *Pseudomonas solanacearum*. Phytopathology 52:726.

- Buddenhagen, I.W. 1961. Bacterial wilt of bananas: history and known distribution. Tropical Agriculture 38:107-121.
- Castillo, J.A., and Greenberg, J.T. 2007. Evolutionary dynamics of *Ralstonia solanacearum*. Applied and environmental microbiology 73:1225-1238.
- Cellier, G., and Prior, P. 2010. Deciphering phenotypic diversity of *Ralstonia* solanacearum strains pathogenic to potato. Phytopathology 100:1250-1261.
- Cellier, G., Remenant, B., Chiroleu, F., Lefeuvre, P., and Prior, P. 2012. Phylogeny and population structure of brown rot- and Moko disease-causing strains of *Ralstonia solanacearum* phylotype II. Applied and environmental microbiology 78:2367-2375.
- Chen, Y., Ren, X., Zhou, X., Huang, L., Yan, L., Lei, Y., Liao, B., Huang, J., Huang, S., Wei, W., and Jiang, H. 2014. Dynamics in the resistant and susceptible peanut (Arachis hypogaea L.) root transcriptome on infection with the *Ralstonia solanacearum*. BMC genomics 15:1078.
- Clough, S.J., Lee, K.E., Schell, M.A., and Denny, T.P. 1997. A two-component system in *Ralstonia* (*Pseudomonas*) *solanacearum* modulates production of *PhcA*regulated virulence factors in response to 3-hydroxypalmitic acid methyl ester. J. Bacteriol. 179:3639-3648.
- Cohan, F.M. 2001. Bacterial species and speciation. Systematic biology 50:513-524.
- Cohan, F.M., and Perry, E.B. 2007. A systematics for discovering the fundamental units of bacterial diversity. Current biology : CB 17:R373-386.
- Cohen, A.S., Najarian, D., Smith, J.A., and Karger, B.L. 1988. Rapid separation of DNA restriction fragments using capillary electrophoresis. J Chromatogr 458:323-333.
- Coll, N.S., and Valls, M. 2013. Current knowledge on the *Ralstonia solanacearum* type III secretion system. Microb Biotechnol 6:614-620.
- Collins, F.S., Morgan, M., and Patrinos, A. 2003. The Human Genome Project: lessons from large-scale biology. Science 300:286-290.
- Cook, D., and Sequeira, L. 1994. Strain differentiation of *Pseudomonas* solanacearum by molecular genetic methods. Pages 77-93 in: Bacterial wilt: the disease and its causative agent, *Pseudomonas solanacearum*, A.C. Hayward and G.L. Hartman, eds. CAB International, Wallingford, United Kingdom.
- Cook, D., Barlow, E., and Sequeira, L. 1989. Genetic diversity of *Pseudomonas* solanacearum: detection of restriction fragment polymorphisms with DNA probes that specify virulence and hypersensitive response. Molecular Plant-Microbe Interactions 2:113-121.
- Cunnac, S., Boucher, C., and Genin, S. 2004. Characterization of the *cis*-acting regulatory element controlling *HrpB*-mediated activation of the type III secretion system and effector genes in *Ralstonia solanacearum*. J. Bacteriol. 186:2309-2318.
- Dacheux, D., Goure, J., Chabert, J., Usson, Y., and Attree, I. 2001. Pore-forming activity of type III system-secreted proteins leads to oncosis of *Pseudomonas aeruginosa*-infected macrophages. Mol Microbiol 40:76-85.

- Dacheux, D., Epaulard, O., de Groot, A., Guery, B., Leberre, R., Attree, I., Polack, B., and Toussaint, B. 2002. Activation of the *Pseudomonas aeruginosa* type III secretion system requires an intact pyruvate dehydrogenase aceAB operon. Infection and immunity 70:3973-3977.
- Dalsing, B.L., and Allen, C. 2014. Nitrate assimilation contributes to *Ralstonia solanacearum* root attachment, stem colonization, and virulence. J Bacteriol 196:949-960.
- Delaspre, F., Nieto Penalver, C.G., Saurel, O., Kiefer, P., Gras, E., Milon, A., Boucher, C., Genin, S., and Vorholt, J.A. 2007. The *Ralstonia solanacearum* pathogenicity regulator HrpB induces 3-hydroxy-oxindole synthesis.
 Proceedings of the National Academy of Sciences of the United States of America 104:15870-15875.
- Deloger, M., El Karoui, M., and Petit, M.A. 2009. A genomic distance based on MUM indicates discontinuity between most bacterial species and genera. J Bacteriol 191:91-99.
- Denny, T.P., and Baek, S.R. 1991. Genetic evidence that extracellular polysaccharide is a virulence factor of *Pseudomonas solanacearum*. Molecular Plant-Microbe Interactions 4:198-206.
- Deslandes, L., Olivier, J., Peeters, N., Feng, D.X., Khounlotham, M., Boucher, C., Somssich, I., Genin, S., and Marco, Y. 2003. Physical interaction between RRS1-R, a protein conferring resistance to bacterial wilt, and PopP2, a type III effector targeted to the plant nucleus. Proceedings of the National Academy of Sciences of the United States of America 100:8024-8029.
- Dong, S., Stam, R., Cano, L.M., Song, J., Sklenar, J., Yoshida, K., Bozkurt, T.O., Oliva, R., Liu, Z., Tian, M., Win, J., Banfield, M.J., Jones, A.M., van der Hoorn, R.A., and Kamoun, S. 2014. Effector specialization in a lineage of the Irish potato famine pathogen. Science 343:552-555.
- Dressman, D., Yan, H., Traverso, G., Kinzler, K.W., and Vogelstein, B. 2003. Transforming single DNA molecules into fluorescent magnetic particles for detection and enumeration of genetic variations. Proceedings of the National Academy of Sciences of the United States of America 100:8817-8822.
- Drossman, H., Luckey, J.A., Kostichka, A.J., D'Cunha, J., and Smith, L.M. 1990. Highspeed separations of DNA sequencing reactions by capillary electrophoresis. Anal Chem 62:900-903.
- Eden-Green, S. 1994. Banana Blood Disease. INIBAP Musa Disease Fact Sheet No.3.
- Eden-Green, S.J., and Adhi, E.M. 1986. Sumatra disease of cloves and *Pseudomonas* solanacearum. Bacterial Wilt Newsletter 1:2-3.
- Edwards, A., Civitello, A., Hammond, H.A., and Caskey, C.T. 1991. DNA typing and genetic mapping with trimeric and tetrameric tandem repeats. American Journal of Human Genetics 49:746-756.
- El-Metwally, S., Hamza, T., Zakaria, M., and Helmy, M. 2013. Next-generation sequence assembly: four stages of data processing and computational challenges. PLoS computational biology 9:e1003345.

- Elphinstone, J.G. 2005. The current bacterial wilt situation: A global overview. Pages 9-28 in: Bacterial wilt disease and the *Ralstonia solanacearum* species complex, C. Allen, P. Prior, and A.C. Hayward, eds. APS Press, St Paul, MN.
- Fegan, M. 2005. Bacterial wilt disease of Banana: evolution and ecology. Pages 379-386 in: Bacterial wilt disease and the *Ralstonia solanacearum* species complex, C. Allen, P. Prior, and A.C. Hayward, eds. APS Press, St Paul, MN.
- Fegan, M., and Prior, P. 2005. How complex is the "*Ralstonia solanacearum* species complex". Pages 449-461 in: Bacterial wilt disease and the *Ralstonia solanacearum* species complex, C. Allen, P. Prior, and A.C. Hayward, eds. APS Press, St Paul, MN.
- Fegan, M., and Prior, P. 2006. Diverse members of the *Ralstonia solanacearum* species complex cause bacterial wilts of banana. Australasian Plant Pathology 35:93-101.
- Ferre, F. 1992. Quantitative or semi-quantitative PCR: reality versus myth. PCR methods and applications 2:1-9.
- Fire, A., Xu, S., Montgomery, M.K., Kostas, S.A., Driver, S.E., and Mello, C.C. 1998. Potent and specific genetic interference by double-stranded RNA in Caenorhabditis elegans. Nature 391:806-811.
- Flavier, A.B., Clough, S.J., Schell, M.A., and Denny, T.P. 1997. Identification of 3hydroxypalmitic acid methyl ester as a novel autoregulator controlling virulence in *Ralstonia solanacearum*. Molecular microbiology 26:251-259.
- Flores-Cruz, Z., and Allen, C. 2009. *Ralstonia solanacearum* encounters an oxidative environment during tomato infection. Molecular plant-microbe interactions : MPMI 22:773-782.
- French, E., Martin, C., and Nydegger, U. 1977. Races and biovars of Pseudomonas solanacearum that affect potatoes. . American Potato Journal 54:10:479-480.
- French, E.R. (1986). Interaction between strains of *Pseudomonas solanacearum*, its hosts and the environment. In Bacterial wilt disease in Asia and the South Pacific: proceedings n°13 of an international workshop held at PCARRD, Los Banos, Philippines, 8-10 October 1985, G. Persley, ed (Canberra, Australia: Australian Centre for International Agricultural Research), pp. 99-104.
- Garrity, G.M., Bell, J.A., and Lilburn, T. 2005. Bergey's Manual of Systematic Bacteriology. Originally published by Williams & Wilkins, 1984, Baltimore.
- Gäumann, E. 1921. Onderzoekingen over de bloedziekte der bananen op Celebes I. Mededelingen van het Instituut voor Plantenziekten 50:47.
- Gäumann, E. 1923. Onderzoekingen over de bloedziekte der bananen op Celebes II. Mededelingen van het Instituut voor Plantenziekten 59:45.
- Genin, S., and Denny, T.P. 2012. Pathogenomics of the *Ralstonia solanacearum* species complex. Annual Review of Phytopathology 50:67-89.
- Genin, S., Brito, B., Denny, T.P., and Boucher, C. 2005. Control of the *Ralstonia solanacearum* Type III secretion system (Hrp) genes by the global virulence regulator PhcA. FEBS letters 579:2077-2081.
- Gillings, M.R., and Fahy, P. 1994. Genomic Fingerprinting: towards a unified view of the *Pseudomonas solanacarum* species complex. Pages 95-112 in: Bacterial

wilt: the disease and its causative agent, *Pseudomonas solanacearum*, A.C. Hayward and G.L. Hartman, eds. CAB International, Wallingford, United Kingdom.

- Gonzalez, A., Plener, L., Restrepo, S., Boucher, C., and Genin, S. 2011. Detection and functional characterization of a large genomic deletion resulting in decreased pathogenicity in *Ralstonia solanacearum* race 3 biovar 2 strains. Environmental microbiology 13:3172-3185.
- Gonzalez, E.T., and Allen, C. 2003. Characterization of a *Ralstonia solanacearum* operon required for polygalacturonate degradation and uptake of galacturonic acid. Molecular plant-microbe interactions : MPMI 16:536-544.

Grimault, V., Anais, G., and Prior, P. 1994a. Distribution of *Pseudomonas* solanacearum in the stem tissues of tomato plants with different levels of resistance to bacterial wilt. Plant Pathol. 43:663-668.

- Grimault, V., Gelie, B., Lemattre, M., Prior, P., and Schmit, J. 1994b. Comparative histology of resistant and susceptible tomato cultivars infected by *Pseudomonas solanacearum*. Physiological and Molecular Plant Pathology 44:105-123
- Guidot, A., Prior, P., Schoenfeld, J., Carrere, S., Genin, S., and Boucher, C. 2007.
 Genomic structure and phylogeny of the plant pathogen *Ralstonia* solanacearum inferred from gene distribution analysis. J. Bacteriol. 189:377-387.
- Guidot, A., Jiang, W., Ferdy, J.B., Thebaud, C., Barberis, P., Gouzy, J., and Genin, S.
 2014. Multihost experimental evolution of the pathogen *Ralstonia* solanacearum unveils genes involved in adaptation to plants. Molecular biology and evolution 31:2913-2928.
- Harismendy, O., Ng, P.C., Strausberg, R.L., Wang, X., Stockwell, T.B., Beeson, K.Y., Schork, N.J., Murray, S.S., Topol, E.J., Levy, S., and Frazer, K.A. 2009.
 Evaluation of next generation sequencing platforms for population targeted sequencing studies. Genome biology 10:R32.
- Hayward, A., Sequeira, L., French, E., El-Nashar, H., and Nydegger, U. 1992. Tropical variant of biovar 2 of *Pseudomonas solanacearum*. J. Phyto Pathol. 82: 608. J. Phyto Pathol:82:608.
- Hayward, A.C. 1964. Characteristics of *Pseudomonas solanacearum*. Journal of Applied Bacteriology 27:265-277.
- Hayward, A.C. 1991. Biology and epidemiology of bacterial wilt caused by *Pseudomonas solanacearum*. Annual Review of Phytopathology 29:65-87.
- He, L.Y., Sequeira, L., and Kelman, A. 1983. Characteristics of strains of *Pseudomonas solanacearum* from China. Plant Disease 67:1357-1361.
- Huang, J., and Schell, M. 1995. Molecular characterization of the *eps* gene cluster of *Pseudomonas solanacearum* and its transcriptional regulation at a single promotor. Molecular microbiology 16:977-989.
- Huang, J., Yindeeyoungyeon, W., Garg, R.P., Denny, T.P., and Schell, M.A. 1998.Joint transcriptional control of *xpsR*, the universal signal integrator of the *Ralstonia solanacearum* virulence gene regulatory network, by a response

regulator and a *LysR*-type transcriptional activator. J. Bacteriol. 180:2736-2743.

- Idury, R.M., and Waterman, M.S. 1995. A new algorithm for DNA sequence assembly. Journal of computational biology : a journal of computational molecular cell biology 2:291-306.
- Jacobs, J.M., Babujee, L., Meng, F., Milling, A., and Allen, C. 2012. The in planta transcriptome of *Ralstonia solanacearum*: conserved physiological and virulence strategies during bacterial wilt of tomato. MBio 3.
- Jalan, N., Kumar, D., Andrade, M.O., Yu, F., Jones, J.B., Graham, J.H., White, F.F., Setubal, J.C., and Wang, N. 2013. Comparative genomic and transcriptome analyses of pathotypes of *Xanthomonas citri* subsp. citri provide insights into mechanisms of bacterial virulence and host range. BMC genomics 14:551.
- Jensen, L.J., Julien, P., Kuhn, M., von Mering, C., Muller, J., Doerks, T., and Bork, P. 2008. eggNOG: automated construction and annotation of orthologous groups of genes. Nucleic acids research 36:D250-254.
- Jeong, Y., Cheong, H., Choi, O., Kim, J.K., Kang, Y., Kim, J., Lee, S., Koh, S., Moon, J.S., and Hwang, I. 2011. An HrpB-dependent but type III-independent extracellular aspartic protease is a virulence factor of *Ralstonia solanacearum*. Mol Plant Pathol 12:373-380.
- Kang, Y., Liu, H., Genin, S., Schell, M.A., and Denny, T.P. 2002. *Ralstonia solanacearum* requires type 4 pili to adhere to multiple surfaces and for natural transformation and virulence. Molecular microbiology 46:427-437.
- Kao, C.C., Barlow, E., and Sequeira, L. 1992. Extracellular Polysaccharide Is Required for Wild-Type Virulence of *Pseudomonas solanacearum*. J. Bacteriol. 174:1068-1071.
- Kelman, A. 1953. The bacterial wilt caused by *Pseudomonas solanacearum*. A literature review and bibliography, Raleigh, NC, USA.
- Kelman, A., and Sequeira, L. 1965. Root-to-root spread of *Pseudomonas* solanacearum. Phytopathology 55:304-309.
- Konstantinidis, K.T., and Tiedje, J.M. 2005. Genomic insights that advance the species definition for prokaryotes. Proceedings of the National Academy of Sciences of the United States of America 102:2567-2572.
- Konstantinidis, K.T., Ramette, A., and Tiedje, J.M. 2006. The bacterial species definition in the genomic era. Philosophical transactions of the Royal Society of London. Series B, Biological sciences 361:1929-1940.
- Kriventseva, E.V., Rahman, N., Espinosa, O., and Zdobnov, E.M. 2008. OrthoDB: the hierarchical catalog of eukaryotic orthologs. Nucleic acids research 36:D271-275.
- Lambert, C.D. (2002). Agricultural Bioterrorism Protection Act of 2002; Possession, Use, and Transfer of Biological; Agents and Toxins; Interim Final Rule, A.a.P.H.I. Service, ed (Federal Register), pp. 76907-76938.
- Langer-Safer, P.R., Levine, M., and Ward, D.C. 1982. Immunological method for mapping genes on Drosophila polytene chromosomes. Proceedings of the National Academy of Sciences of the United States of America 79:4381-4385.

- Lavie, M., Shillington, E., Eguiluz, C., Grimsley, N., and Boucher, C. 2002. *PopP1*, a new member of the YopJ/AvrRxv family of type III effector proteins, acts as a host-specificity factor and modulates aggressiveness of *Ralstonia solanacearum*. Molecular Plant-Microbe Interactions 15:1058-1068.
- Lebeau, A., Daunay, M.C., Frary, A., Palloix, A., Wang, J.F., Dintinger, J., Chiroleu, F., Wicker, E., and Prior, P. 2011. Bacterial wilt resistance in tomato, pepper, and eggplant: genetic resources respond to diverse strains in the *Ralstonia solanacearum* species complex. Phytopathology 101:154-165.
- Lefeuvre, P., Cellier, G., Remenant, B., Chiroleu, F., and Prior, P. 2013. Constraints on genome dynamics revealed from gene distribution among the *Ralstonia solanacearum* species. PloS one 8:e63155.
- Li, L., Stoeckert, C.J., Jr., and Roos, D.S. 2003. OrthoMCL: identification of ortholog groups for eukaryotic genomes. Genome research 13:2178-2189.
- Li, X., Dorsch, M., Del Dot, T., Sly, L., Stackebrandt, E., and Hayward, A.C. 1993. Phylogenetic studies of the rRNA group II pseudomonads based on 16S rRNA gene sequences. Journal of Applied Bacteriology 74:324-329.
- Liang, P., and Pardee, A.B. 1992. Differential display of eukaryotic messenger RNA by means of the polymerase chain reaction. Science 257:967-971.
- Liu, H., Zhang, S., Schell, M.A., and Denny, T.P. 2005. Pyramiding unmarked deletions in *Ralstonia solanacearum* shows that secreted proteins in addition to plant cell-wall-degrading enzymes contribute to virulence. Molecular plant-microbe interactions : MPMI 18:1296-1305.
- Lohou, D., Turner, M., Lonjon, F., Cazale, A.C., Peeters, N., Genin, S., and Vailleau, F.
 2014. HpaP modulates type III effector secretion in *Ralstonia solanacearum* and harbours a substrate specificity switch domain essential for virulence. Mol Plant Pathol 15:601-614.
- Lowe, T.M., Ailloud, F., and Allen, C. 2015. Hydroxycinnamic Acid Degradation, a Broadly Conserved Trait, Protects *Ralstonia solanacearum* from Chemical Plant Defenses and Contributes to Root Colonization and Virulence. Molecular plant-microbe interactions : MPMI 28:286-297.
- Luckey, J.A., Drossman, H., Kostichka, A.J., Mead, D.A., D'Cunha, J., Norris, T.B., and Smith, L.M. 1990. High speed DNA sequencing by capillary electrophoresis. Nucleic acids research 18:4417-4421.
- Mahan, M.J., Slauch, J.M., and Mekalanos, J.J. 1993. Selection of bacterial virulence genes that are specifically induced in host tissues. Science 259:686-688.
- Mahan, M.J., Heithoff, D.M., Sinsheimer, R.L., and Low, D.A. 2000. Assessment of bacterial pathogenesis by analysis of gene expression in the host. Annual review of genetics 34:139-164.
- Mahbou Somo Toukam, G., Cellier, G., Wicker, E., Guilbaud, C., Kahane, R., Allen, C., and Prior, P. 2009. Broad Diversity of *Ralstonia solanacearum* Strains in Cameroon. Plant Disease 93:1123-1130.
- Mansfield, J., Genin, S., Magori, S., Citovsky, V., Sriariyanum, M., Ronald, P., Dow, M., Verdier, V., Beer, S.V., Machado, M.A., Toth, I., Salmond, G., and Foster,

G.D. 2012. Top 10 plant pathogenic bacteria in molecular plant pathology. Molecular Plant Pathology 13:614-629.

- Martin, C., French, E., and Nydegger, U. 1982. Strains of *Pseudomonas* solanacearum affecting Solanaceae In the Americas. Plant Disease 66:6:458-460
- McGarvey, J.A., Denny, T.P., and Schell, M.A. 1999. Spatial-Temporal and Quantitative Analysis of Growth and EPS I Production by *Ralstonia solanacearum* in Resistant and Susceptible Tomato Cultivars. Phytopathology 89:1233-1239.
- Meng, F., Yao, J., and Allen, C. 2011. A MotN mutant of *Ralstonia solanacearum* is hypermotile and has reduced virulence. J. Bacteriol. 193:2477-2486.
- Mhedbi-Hajri, N., Hajri, A., Boureau, T., Darrasse, A., Durand, K., Brin, C., Fischer-Le Saux, M., Manceau, C., Poussier, S., Pruvost, O., Lemaire, C., and Jacques, M.A. 2013. Evolutionary history of the plant pathogenic bacterium *Xanthomonas axonopodis*. PloS one 8:e58474.
- Miller, J.R., Koren, S., and Sutton, G. 2010. Assembly algorithms for next-generation sequencing data. Genomics 95:315-327.
- Milling, A., Babujee, L., and Allen, C. 2011. *Ralstonia solanacearum* extracellular polysaccharide is a specific elicitor of defense responses in wilt-resistant tomato plants. PloS one 6:e15853.
- Milling, A., Meng, F., Denny, T.P., and Allen, C. 2009. Interactions with hosts at cool temperatures, not cold tolerance, explain the unique epidemiology of *Ralstonia solanacearum* race 3 biovar 2. Phytopathology 99:1127-1134.
- Monteiro, F., Genin, S., van Dijk, I., and Valls, M. 2012. A luminescent reporter evidences active expression of *Ralstonia solanacearum* type III secretion system genes throughout plant infection. Microbiology 158:2107-2116.
- Mukaihara, T., and Tamura, N. 2009. Identification of novel *Ralstonia solanacearum* type III effector proteins through translocation analysis of hrpB-regulated gene products. Microbiology 155:2235-2244.
- Mukaihara, T., Tamura, N., and Iwabuchi, M. 2010. Genome-wide identification of a large repertoire of *Ralstonia solanacearum* type III effector proteins by a new functional screen. Molecular plant-microbe interactions : MPMI 23:251-262.
- Myers, E.W. 1995. Toward simplifying and accurately formulating fragment assembly. Journal of computational biology : a journal of computational molecular cell biology 2:275-290.
- O'Brien, K.P., Remm, M., and Sonnhammer, E.L. 2005. Inparanoid: a comprehensive database of eukaryotic orthologs. Nucleic acids research 33:D476-480.
- Occhialini, A., Cunnac, S., Reymond, N., Genin, S., and Boucher, C. 2005. Genomewide analysis of gene expression in *Ralstonia solanacearum* reveals that the hrpB gene acts as a regulatory switch controlling multiple virulence pathways. Molecular plant-microbe interactions : MPMI 18:938-949.

Okoniewski, M.J., and Miller, C.J. 2006. Hybridization interactions between probesets in short oligo microarrays lead to spurious correlations. BMC bioinformatics 7:276.

Orgambide, G., Montrozier, H., Servin, P., Roussel, J., Trigalet-Demery, D., and Trigalet, A. 1991. High heterogeneity of the exopolysaccharides of *Pseudomonas solanacearum* strain GMI 1000 and the complete structure of the major polysaccharide. Journal of Biological Chemistry 266:8312-8321.

Palleroni, N.J., and Doudoroff, M. 1971. Phenotypic characterization and deoxyribonucleic acid homologies of *Pseudomonas solanacearum*. J. Bacteriol. 107:690-696.

Pegg, G. 1985. Life in a black hole – the micro-environment of the vascular pathogen. . Transactions of the British Mycological Society

85:1-20.

- Pevzner, P.A., Tang, H., and Waterman, M.S. 2001. An Eulerian path approach to DNA fragment assembly. Proceedings of the National Academy of Sciences of the United States of America 98:9748-9753.
- Plener, L., Manfredi, P., Valls, M., and Genin, S. 2010. PrhG, a transcriptional regulator responding to growth conditions, is involved in the control of the type III secretion system regulon in *Ralstonia solanacearum*. J Bacteriol 192:1011-1019.
- Pop, M., and Salzberg, S.L. 2008. Bioinformatics challenges of new sequencing technology. Trends in genetics : TIG 24:142-149.
- Poueymiro, M., and Genin, S. 2009. Secreted proteins from *Ralstonia solanacearum*: a hundred tricks to kill a plant. Current Opinion in Microbiology 12:44-52.

Poueymiro, M., Cunnac, S., Barberis, P., Deslandes, L., Peeters, N., Cazale-Noel, A.C., Boucher, C., and Genin, S. 2009. Two type III secretion system effectors from *Ralstonia solanacearum* GMI1000 determine host-range specificity on tobacco. Molecular plant-microbe interactions : MPMI 22:538-550.

Poussier, S., Trigalet-Demery, D., Vandewalle, P., Goffinet, B., Luisetti, J., and Trigalet, A. 2000. Genetic diversity of *Ralstonia solanacearum* as assessed by PCR-RFLP of the *hrp* gene region, AFLP and 16S rRNA sequence analysis, and identification of an African subdivision. Microbiology 146 (Pt 7):1679-1692.

- Prober, J.M., Trainor, G.L., Dam, R.J., Hobbs, F.W., Robertson, C.W., Zagursky, R.J., Cocuzza, A.J., Jensen, M.A., and Baumeister, K. 1987. A system for rapid DNA sequencing with fluorescent chain-terminating dideoxynucleotides. Science 238:336-341.
- Rediers, H., Rainey, P.B., Vanderleyden, J., and De Mot, R. 2005. Unraveling the secret lives of bacteria: use of in vivo expression technology and differential fluorescence induction promoter traps as tools for exploring niche-specific gene expression. Microbiology and molecular biology reviews : MMBR 69:217-261.
- Remenant, B., Babujee, L., Lajus, A., Medigue, C., Prior, P., and Allen, C. 2012. Sequencing of K60, type strain of the major plant pathogen *Ralstonia solanacearum*. J. Bacteriol. 194:2742-2743.

- Remenant, B., de Cambiaire, J.C., Cellier, G., Jacobs, J.M., Mangenot, S., Barbe, V., Lajus, A., Vallenet, D., Medigue, C., Fegan, M., Allen, C., and Prior, P. 2011. *Ralstonia syzygii*, the Blood Disease Bacterium and some Asian *R. solanacearum* strains form a single genomic species despite divergent lifestyles. PloS one 6:e24356.
- Remenant, B., Coupat-Goutaland, B., Guidot, A., Cellier, G., Wicker, E., Allen, C.,
 Fegan, M., Pruvost, O., Elbaz, M., Calteau, A., Salvignol, G., Mornico, D.,
 Mangenot, S., Barbe, V., Medigue, C., and Prior, P. 2010. Genomes of three
 tomato pathogens within the *Ralstonia solanacearum* species complex reveal
 significant evolutionary divergence. BMC genomics 11:379.
- Rietsch, A., Wolfgang, M.C., and Mekalanos, J.J. 2004. Effect of metabolic imbalance on expression of type III secretion genes in *Pseudomonas aeruginosa*. Infection and immunity 72:1383-1390.
- Roach, J.C., Boysen, C., Wang, K., and Hood, L. 1995. Pairwise end sequencing: a unified approach to genomic mapping and sequencing. Genomics 26:345-353.
- Roberts, D.P., Denny, T.P., and Schell, M.A. 1988. Cloning of the *egl* gene of *Pseudomonas solanacearum* and analysis of its role in phytopathogenicity. J. Bacteriol. 170:1445-1451.
- Roberts, S.J., Eden-Green, S.J., Jones, P., and Ambler, D.J. 1990. *Pseudomonas syzygii*, sp. nov., the cause of Sumatra disease of cloves. Syst. Appl. Microbiol. 13:34-43.
- Rodríguez-Ezpeleta, N., Hackenberg, M., and Aransay, A. 2012. Bioinformatics for High Throughput Sequencing. Springer.
- Rouillard, J.M., Zuker, M., and Gulari, E. 2003. OligoArray 2.0: design of oligonucleotide probes for DNA microarrays using a thermodynamic approach. Nucleic acids research 31:3057-3062.
- Safni, I., Cleenwerck, I., De Vos, P., Fegan, M., Sly, L., and Kappler, U. 2014. Polyphasic taxonomic revision of the *Ralstonia solanacearum* species complex: proposal to emend the descriptions of *Ralstonia solanacearum* and *Ralstonia syzygii* and reclassify current *R. syzygii* strains as *Ralstonia syzygii* subsp. syzygii subsp. nov., *R. solanacearum* phylotype IV strains as *Ralstonia syzygii* subsp. indonesiensis subsp. nov., banana blood disease bacterium strains as *Ralstonia syzygii* subsp. celebesensis subsp. nov. and *R. solanacearum* phylotype I and III strains as *Ralstonia pseudosolanacearum* sp. nov. International journal of systematic and evolutionary microbiology 64:3087-3103.
- Salanoubat, M., Genin, S., Artiguenave, F., Gouzy, J., Mangenot, S., Arlat, M.,
 Billault, A., Brottier, P., Camus, J.C., Cattolico, L., Chandler, M., Choisne, N.,
 Claudel-Renard, C., Cunnac, S., Demange, N., Gaspin, C., Lavie, M., Moisan,
 A., Robert, C., Saurin, W., Schiex, T., Siguier, P., Thebault, P., Whalen, M.,
 Wincker, P., Levy, M., Weissenbach, J., and Boucher, C.A. 2002. Genome
 sequence of the plant pathogen *Ralstonia solanacearum*. Nature 415:497-502.

- Schena, M., Shalon, D., Davis, R.W., and Brown, P.O. 1995. Quantitative monitoring of gene expression patterns with a complementary DNA microarray. Science 270:467-470.
- Schloter, M., Lebuhn, M., Heulin, T., and Hartmann, A. 2000. Ecology and evolution of bacterial microdiversity. FEMS microbiology reviews 24:647-660.
- Shalon, D., Smith, S.J., and Brown, P.O. 1996. A DNA microarray system for analyzing complex DNA samples using two-color fluorescent probe hybridization. Genome research 6:639-645.
- Shen, D.K., Filopon, D., Chaker, H., Boullanger, S., Derouazi, M., Polack, B., and Toussaint, B. 2008. High-cell-density regulation of the *Pseudomonas aeruginosa* type III secretion system: implications for tryptophan catabolites. Microbiology 154:2195-2208.
- Smith, E.F. 1896. A bacterial disease of tomato, eggplant, and Irish potato (Bacterium solanacearum nov. sp.). USDA Div. Veg. Physiol. Pathol. Bull. 12:191.
- Smith, L.M., Fung, S., Hunkapiller, M.W., Hunkapiller, T.J., and Hood, L.E. 1985. The synthesis of oligonucleotides containing an aliphatic amino group at the 5' terminus: synthesis of fluorescent DNA primers for use in DNA sequence analysis. Nucleic acids research 13:2399-2412.
- Smith, L.M., Sanders, J.Z., Kaiser, R.J., Hughes, P., Dodd, C., Connell, C.R., Heiner, C., Kent, S.B., and Hood, L.E. 1986. Fluorescence detection in automated DNA sequence analysis. Nature 321:674-679.
- Soguilon, C.E., Magnaye, L.V., and Natural, M.P. 1995. La maladie de Bugtok du bananier. INIBAP Maladie des Musa Fiche technique No.6.
- Sole, M., Popa, C., Mith, O., Sohn, K.H., Jones, J.D., Deslandes, L., and Valls, M. 2012. The awr gene family encodes a novel class of *Ralstonia solanacearum* type III effectors displaying virulence and avirulence activities. Molecular plant-microbe interactions : MPMI 25:941-953.
- Soneson, C., and Delorenzi, M. 2013. A comparison of methods for differential expression analysis of RNA-seq data. BMC bioinformatics 14:91.
- Staden, R. 1979. A strategy of DNA sequencing employing computer programs. Nucleic acids research 6:2601-2610.
- Swanson, J.K., Yao, J., Tans-Kersten, J., and Allen, C. 2005. Behavior of *Ralstonia solanacearum* Race 3 Biovar 2 During Latent and Active Infection of Geranium. Phytopathology 95:136-143.
- Taghavi, M., Hayward, C., Sly, L.I., and Fegan, M. 1996. Analysis of the phylogenetic relationships of strains of *Burkholderia solanacearum, Pseudomonas syzygii*, and the blood disease bacterium of banana based on 16S rRNA gene sequences. International Journal of Systematic Bacteriology 46:10-15.
- Tamura, N., Murata, Y., and Mukaihara, T. 2005. Isolation of *Ralstonia* solanacearum hrpB constitutive mutants and secretion analysis of hrpBregulated gene products that share homology with known type III effectors and enzymes. Microbiology 151:2873-2884.

Tans-Kersten, J., Huang, H., and Allen, C. 2001. *Ralstonia solanacearum* needs motility for invasive virulence on tomato. J. Bacteriol. 183:3597-3605.

- Tasset, C., Bernoux, M., Jauneau, A., Pouzet, C., Briere, C., Kieffer-Jacquinod, S., Rivas, S., Marco, Y., and Deslandes, L. 2010. Autoacetylation of the *Ralstonia solanacearum* effector PopP2 targets a lysine residue essential for RRS1-Rmediated immunity in Arabidopsis. PLoS Pathog 6:e1001202.
- Tatusov, R.L., Koonin, E.V., and Lipman, D.J. 1997. A genomic perspective on protein families. Science 278:631-637.
- Thellin, O., Zorzi, W., Lakaye, B., De Borman, B., Coumans, B., Hennen, G., Grisar, T., Igout, A., and Heinen, E. 1999. Housekeeping genes as internal standards: use and limits. Journal of biotechnology 75:291-295.
- Trachana, K., Larsson, T.A., Powell, S., Chen, W.H., Doerks, T., Muller, J., and Bork, P. 2011. Orthology prediction methods: a quality assessment using curated protein families. BioEssays : news and reviews in molecular, cellular and developmental biology 33:769-780.
- Vasse, J., Frey, P., and Trigalet, A. 1995. Microscopic studies of intercellular infection and protoxylem invasion of tomato roots by *Pseudomonas solanacearum*. Molecular Plant-Microbe Interactions 8:241-251.
- Vasse, J., Genin, S., Frey, P., Boucher, C., and Brito, B. 2000. The *hrpB* and *hrpG* regulatory genes of *Ralstonia solanacearum* are required for different stages of the tomato root infection process. Molecular plant-microbe interactions : MPMI 13:259-267.
- Velculescu, V.E., Zhang, L., Vogelstein, B., and Kinzler, K.W. 1995. Serial analysis of gene expression. Science 270:484-487.
- Volkenandt, M., Dicker, A.P., Banerjee, D., Fanin, R., Schweitzer, B., Horikoshi, T., Danenberg, K., Danenberg, P., and Bertino, J.R. 1992. Quantitation of gene copy number and mRNA using the polymerase chain reaction. Proc Soc Exp Biol Med 200:1-6.
- Waller, J.M., and Sitepu, D. 1975. Sumatra disease of cloves in Indonesia. International Journal of Pest Management 21:141-147.
- Wang, Z., Gerstein, M., and Snyder, M. 2009. RNA-Seq: a revolutionary tool for transcriptomics. Nature reviews. Genetics 10:57-63.
- Welsh, J., Chada, K., Dalal, S.S., Cheng, R., Ralph, D., and McClelland, M. 1992. Arbitrarily primed PCR fingerprinting of RNA. Nucleic acids research 20:4965-4970.
- Wicker, E., Grassart, L., Coranson-Beaudu, R., Mian, D., and Prior, P. 2009.
 Epidemiological evidence for the emergence of a new pathogenic variant of *Ralstonia solanacearum* in Martinique (French West Indies). Plant Pathol. 58:853-851.
- Wicker, E., Grassart, L., Coranson Beaudu, R., Mian, D., Guilbaud, C., and Prior, P.
 2005. Emerging strains of *Ralstonia solanacearum* in Martinique (French West Indies): a case study for epidemiology of bacterial wilt. Acta Horticulturae:145-152.

- Wicker, E., Grassart, L., Coranson-Beaudu, R., Mian, D., Guilbaud, C., Fegan, M., and Prior, P. 2007. *Ralstonia solanacearum* strains from Martinique (French West Indies) exhibiting a new pathogenic potential. Applied and environmental microbiology 73:6790-6801.
- Winter, S.E., Thiennimitr, P., Winter, M.G., Butler, B.P., Huseby, D.L., Crawford, R.W., Russell, J.M., Bevins, C.L., Adams, L.G., Tsolis, R.M., Roth, J.R., and Baumler, A.J. 2010. Gut inflammation provides a respiratory electron acceptor for *Salmonella*. Nature 467:426-429.
- Yabuuchi, E., Kosako, Y., Yano, I., Hotta, H., and Nishiuchi, Y. 1995. Transfer of two Burkholderia and an Alcaligenes species to Ralstonia gen. Nov.: Proposal of Ralstonia pickettii (Ralston, Palleroni and Doudoroff 1973) comb. Nov., Ralstonia solanacearum (Smith 1896) comb. Nov. and Ralstonia eutropha (Davis 1969) comb. Nov. Microbiol Immunol 39:11:897-904.
- Yabuuchi, E., Kosako, Y., Oyaizu, H., Yano, I., Hotta, H., Hashimoto, Y., Ezaki, T., and Arakawa, M. 1992. Proposal of *Burkholderia* gen. nov. and transfer of seven species of the genus *Pseudomonas* homology group II to the new genus, with the type species *Burkholderia cepacia* (Palleroni and Holmes 1981) comb. nov. Microbiology and Immunology 36:1251-1275.
- Yao, J., and Allen, C. 2006. Chemotaxis is required for virulence and competitive fitness of the bacterial wilt pathogen *Ralstonia solanacearum*. J. Bacteriol. 188:3697-3708.
- Yoshimochi, T., Hikichi, Y., Kiba, A., and Ohnishi, K. 2009. The global virulence regulator PhcA negatively controls the *Ralstonia solanacearum* hrp regulatory cascade by repressing expression of the PrhIR signaling proteins. J. Bacteriol. 191:3424-3428.
- Zhi, D., Raphael, B.J., Price, A.L., Tang, H., and Pevzner, P.A. 2006. Identifying repeat domains in large genomes. Genome biology 7:R7.
- Zuluaga, A.P., Puigvert, M., and Valls, M. 2013. Novel plant inputs influencing *Ralstonia solanacearum* during infection. Front Microbiol 4:349.

1	Hydroxycinnamic acid degradation, a broadly conserved trait, protects <i>Ralstonia</i>
2	solanacearum from chemical plant defenses and contributes to root colonization and
3	virulence
4	Tiffany M. Lowe ^{1,2} , Florent Ailloud ³ , and Caitilyn Allen ^{2*}
5	
6	¹ Microbiology Doctoral Training Program, University of Wisconsin-Madison,
7	Madison, WI, USA
8	² Department of Plant Pathology, University of Wisconsin-Madison, Madison, WI,
9	USA
10	³ Peuplements Végétaux et Bioagresseurs en Milieu Tropical (UMR PVBMT), INRA-
11	CIRAD, Saint Pierre, La Réunion, France
12	
13	*Corresponding Author: Caitilyn Allen; cza@plantpath.wisc.edu ; 608-262-9578
14	
15	

Lowe, Tiffany - MPMI

16 Abstract

17 Plants produce hydroxycinnamic acid defense compounds (HCAs) to combat 18 pathogens, such as the bacterium *Ralstonia solanacearum*. We showed that an HCA degradation pathway is genetically and functionally conserved across diverse R. 19 20 *solanacearum* strains. Further, a Δfcs (feruloyl-CoA synthetase) mutant that cannot degrade 21 HCAs was less virulent on tomato plants. To understand the role of HCA degradation in 22 bacterial wilt disease, we tested the following hypotheses: HCA degradation helps the 23 pathogen (1) grow, as a carbon source; (2) spread, by reducing physical barriers HCA-24 derived; and (3) **survive** plant antimicrobial compounds. Although HCA degradation enabled *R. solanacearum* growth on HCAs *in vitro*, HCA degradation was dispensable for 25 growth in xylem sap and root exudate, suggesting that HCAs are not significant carbon 26 sources *in planta*. Acetyl-bromide quantification of lignin demonstrated that *R*. 27 *solanacearum* infections did not affect the gross quantity or distribution of stem lignin. 28 29 However, the Δfcs mutant was significantly more susceptible to inhibition by two HCAs: 30 caffeate and *p*-coumarate. Finally, plant colonization assays suggested that HCA 31 degradation facilitates early stages of infection and root colonization. Together, these 32 results indicated that ability to degrade HCAs contributes to bacterial wilt virulence by 33 facilitating root entry and by protecting the pathogen from HCA toxicity.

34

Page 3 of 51

35

Introduction

Lowe, Tiffany - MPMI

Plants produce thousands of phenolic compounds, which play roles in plant 36 37 development and interactions with microbes (Mandal et al., 2010: Naoumkina et al., 2010). Among these are hydroxycinnamic acids (HCAs), which are monocyclic phenylpropanoid 38 39 molecules. Roots exude HCAs and related phenolics to chelate metals, thereby facilitating 40 uptake and transport of metals in the xylem sap (Ishimaru et al., 2011). In response to root 41 pathogens, many plants release *de novo* synthesized HCAs into the rhizosphere, and 42 grapevines infected with *Xylella* accumulate HCAs and HCA-conjugates in their xylem sap 43 (Mandal and Mitra, 2008; Lanoue et al., 2010; Wallis and Chen, 2012). HCAs are broadly

antimicrobial; they disrupt membrane integrity and decouple the respiratory proton
gradient (Fitzgerald et al., 2004; Harris et al., 2010). Additionally, HCAs reinforce protective
physical barriers in plants by cross-linking primary cell wall polysaccharides and by
serving as precursors for the phenolic polymer lignin (Fry et al., 2000; Naoumkina et al.,
2010; Campos et al., 2014).

Plants defend their vascular systems with phenolic-storing cells stationed along the
xylem (Beckman, 2000). These phenolic storing cells decompartmentalize in response to
infection and release phenolics into the xylem lumen, in a process similar to neutrophil
degranulation in animal immunity. Exposing tomato roots to a xylem-dwelling fungal
vascular wilt pathogen, *Fusarium oxysporum* f. sp. *lycopersici*, leads to increased
accumulation of the HCAs ferulate and *p*-coumarate (Mandal and Mitra, 2008).
Ultrastructure studies of xylem infected with the vascular pathogen *Ralstonia*

Lowe, Tiffany - MPMI

R. solanacearum causes bacterial wilt disease, which limits production of key crops
like potato, banana, peanut, and tomato (Elphinstone, 2005). This soil-dwelling pathogen
generally enters hosts through the roots and then colonizes the xylem elements throughout
the plant. Extensive colonization of the xylem ultimately blocks water transport, leading to
stunting and wilting. *R. solanacearum* strains form a large, heterogeneous species complex
that collectively infects hundreds of different plant species(Peeters et al., 2013).

64 Several lines of evidence suggest that hydroxycinnamic acids are involved in tomato 65 interactions with *R. solanacearum*. Quantitative resistance of tomato cultivars against *R.* solanacearum is correlated with early expression of phenylalanine ammonia lyase (PAL). 66 67 which catalyzes the first step in phenylpropanoid biosynthesis (Vanitha et al., 2009). 68 Transcriptomic analysis showed that multiple phenylpropanoid biosynthesis genes are 69 upregulated in *R. solanacearum*-infected, resistant tomato plants compared to healthy 70 plants (Ishihara et al., 2012) (Milling and Allen, unpublished). We previously found that 71 drug efflux pumps protect *R. solanacearum* from the toxicity of many plant defense 72 chemicals, including the HCA caffeate (Brown et al., 2007). More specifically, the genomes 73 of many *R. solanacearum* strains encode an enzymatic pathway that is homologous to a 74 *Pseudomonas fluorescens* pathway that breaks down the HCAs ferulate, *p*-coumarate, and 75 caffeate to central carbon metabolites (Narbad and Gasson, 1998) (Fig. 1). These HCA 76 degradation pathway genes are expressed by *R. solanacearum* cells growing in tomato 77 xylem vessels at the onset of wilt symptoms (Salanoubat et al., 2002; Jacobs et al., 2012).

We explored the hypothesis that HCA degradation contributes to bacterial wilt
disease. We found that HCA degradation is widely conserved in the *R. solanacearum* species
complex. A feruloyl-CoA synthetase mutant (Δ*fcs*) that cannot degrade HCAs had reduced
virulence on tomato, delayed colonization of tomato roots, and increased susceptibility to
the toxicity of the HCAs caffeate and *p*-coumarate.

83 Results

84 **Organization of HCA degradation genes in** *R. solanacearum* **GMI1000**.

85 HCA degradation enzymes encoded by the genes *fcs. fca. vdh. vanAB*, and *pobA* 86 convert the HCAs *p*-coumarate, caffeate, and ferulate to protocatechuate and acetyl-CoA (Fig. 1A). The β -ketoadipate enzymes encoded by the *pca* genes further metabolize 87 88 protocatechuate to the central carbon metabolites succinyl-CoA and a second acetyl-CoA. In 89 *R. solanacearum* strain GMI1000, the HCA degradation and β-ketoadipate genes are 90 organized as five putative operons at three genomic loci (Fig. 1B): fca-vdh-fcs (RSp0225-0227), *vanAB* (RSp0222-0223), *pobA* (RSc02242), *pcaGH* (RSc1141-1142), and *pcaIJFBDC* 91 (RSc2249-2255). 92

We used the Orthologous MAtrix (OMA) browser to investigate the conservation of
genes for HCA and protocatechuate degradation across bacteria (Supplementary Table S2).
OMA uses a strict algorithm to categorize orthologous proteins from complete publically
available genome sequences (Altenhoff et al., 2011). The eukaryotic β-ketoadipate genes
are not homologous to the bacterial genes, so we did not analyze eukaryotic genomes. OMA
analysis indicated that HCA degradation is a rare trait among the 1,281 bacterial strains
considered. Many plant pathogenic bacteria lacked HCA degradation genes, including the

Lowe, Tiffany - MPMI

100	necrotroph Dickeya dadantii 3937, which uses feruloyl-esterases to cleave HCAs from cell
101	wall polysaccharides (Hassan and Hugouvieux-Cotte-Pattat, 2011), and Xylella fastidiosa,
102	which encounters HCAs in grapevine xylem (Wallis and Chen, 2012). Although the OMA
103	database tends to yield false negatives, we gained insight on the prevalence and
104	distribution of this pathway in bacteria because HCA degradation has been functionally
105	characterized in several of the strains included in the OMA database (Parke and Ornston,
106	2003; Plaggenborg et al., 2003; Abdelkafi et al., 2006; Kim et al., 2008; Pérez-Pantoja et al.,
107	2008; Romero-Silva et al., 2013; Campillo et al., 2014). For example, although OMA analysis
108	indicated that Cupriavidus pinatubonensis JMP134 (formerly C. necator and Ralstonia
109	<i>eutropha</i>) lacks 4/14 HCA degradation genes, this strain is known to degrade HCAs.
110	Therefore, we hypothesized that the 33 strains containing more than $10/14$ HCA
111	degradation genes likely degrade HCAs. These strains are predominantly in genera known
112	to spend part of their lifecycles in soil: Burkholderia, Brucella, and Pseudomonas. OMA
113	analysis identified several plant-associated genera that appear to have functional β -
114	ketoadipate pathways but lack the upstream HCA degrading enzymes: Xanthomonas
115	campestris, Rhizobium spp., and Agrobacterium spp. (although Campilo et al. (2014) show
116	that Agrobacterium strain C58 degrades HCAs).
117	The hydroxycinnamic acid (HCA) degradation pathway is broadly conserved in the <i>R</i> .
118	solanacearum species complex.
119	Because hydroxycinnamic acids are common plant metabolites, the ability to

120 degrade these metabolites could benefit *R. solanacearum*. To explore the genetic

121 conservation of the HCA degradation pathway in the large and heterogeneous *R*.

solanacearum species complex, we searched for homologs of HCA degradation genes in the
genomes of 23 available *R. solanacearum* strains (Fig. 2A). Only two strains lacked multiple
HCA degradation genes: Phylotype IIA strain K60 and Phylotype IV Blood Disease
Bacterium (BDB) strain R229. We identified homologs of each HCA degradation gene in the
remaining 21 strains (91%), but in eight of these strains, one or more genes were located
on a contig border or were annotated as putative pseudogenes.

The number of potential pseudogenes and genes lying on contig borders made it 128 129 difficult to predict the HCA degradation ability of a third of the sequenced strains, so we 130 functionally characterized the HCA degradation ability of all available strains. We could not analyze strains Po82, FQY-4, and Y45 since the authors of these published genomes would 131 132 not share their strains (Li et al., 2011; Xu et al., 2011; Cao et al., 2013). Each strain was 133 tested for its ability to grow on the HCAs ferulate (Fer) and *p*-coumarate (Cou) as well as on 134 the pathway intermediates vanillin (Van), vanillate (VA), p-hydroxybenzoate (HBA), and 135 protocatechuate (PCA) (see Fig. 1A). Most strains grew on all tested compounds, except 136 where genomic data indicated an incomplete pathway (Fig 2A). For example, because it 137 lacks *fcs, fca, vdh, vanB, pobA*, and *pcaH*, strain K60 did not grow on any tested substrate. Similarly, BDB strain R229, lacking *fcs, fca, vdh*, and *vanB*, grew only on protocatechuate. 138

In several cases, bioinformatic data did not accurately predict biological function.
Surprisingly, although strains CFBP2957 and Molk2 grew on ferulate, they did not grow on
the ferulate degradation intermediates vanillin (in the case of CFPB2957) or vanillin and
vanillate (in the case of Molk2). It is possible that higher sensitivity to toxicity of vanillin
and vanillate prevented these strains from growing. Several strains with a putatively

Lowe, Tiffany - MPMI

144 pseudogenized *fcs* displayed contrasting growth phenotypes. While strain UW179 grew on 145 all compounds, the phylotype II sequevar 1 (Race 3 biovar 2) strains UW491 and UW551 146 unexpectedly did not grow on ferulate, p-coumarate, vanillin, or vanillate, Further, strains 147 CIP417 and CMR15 grew on intermediate metabolites but not ferulate or *p*-coumarate even 148 though these strains apparently possess complete sets of HCA degradation genes. Taken 149 together, these analyses indicate that most *R. solangcearum* strains can degrade at least 150 some HCAs; the unexpected positive and negative results for growth on HCAs also highlight 151 the importance of functional experiments to confirm genomic analyses. 152 To determine whether HCA degradation contributes to bacterial wilt disease, we

created an *fcs* deletion mutant in the background of phylotype I strain GMI1000. Hereafter, 153 154 strain GMI1000 is referred to as wildtype or WT and the GMI1000 deletion mutant lacking 155 the ferulovl-CoA synthetase open reading frame is referred to as the Δfcs mutant. While WT 156 used HCAs and intermediate phenolics as a carbon source (Fig. 2), the Δfcs mutant did not 157 grow on the HCAs *p*-coumarate, caffeate, or ferulate, as predicted (Fig. 2B). Additionally, 158 the mutant grew as well as wildtype on all pathway intermediates (data not shown). This 159 result confirmed the bioinformatic annotation of this gene, and also confirmed the deletion of the *fcs* gene. Genetic complementation of the mutant with the cloned *fcs* operon under 160 161 control of the native promoter restored its growth on HCAs (Fig. 2B).

162 HCA degradation contributes to *R. solanacearum* virulence on tomato.

We used a naturalistic soil soak virulence assay to measure the contribution of HCA
degradation to *R. solanacearum* virulence on tomato. Bacterial suspensions were poured
Page 9 of 51

Lowe, Tiffany - MPMI

165 into the soil of individually potted unwounded tomato plants, and symptom development166 was measured over time.

167 The Δfcs mutant displayed a modest but significant reduction in virulence on plants 168 grown at the tropical temperature 28°C (Fig. 3A; repeated measure ANOVA; *P*=0.0123). 169 The reduced virulence of the Δfcs mutant did not result from an altered rate of symptom 170 progression. Once they became symptomatic, plants inoculated with either strain 171 progressed to end-stage disease at the same rate (average time was 1.2 and 1.1 days for 172 WT and Δfcs inoculated plants, respectively, between the first symptoms and the highest 173 disease index rating; *P*=0.402, unpaired *t*-test). To determine whether the virulence defect was due to a delay in symptom onset, we used survival analysis. Although survival analysis 174 175 was originally developed to analyze patient outcome data in clinical trials, this statistical 176 tool can analyze any discrete biological events in a time course. This analysis revealed that 177 symptom onset was earlier in WT-inoculated plants than in Δfcs -inoculated plants (Fig. 3B; 178 log-rank Mantel-Cox test; P = 0.0118). The median time until symptom onset was 6 days 179 after WT inoculation and 7 days after Δfcs mutant inoculation. This result suggested that 180 the virulence defect of the Δfcs mutant affects an early stage of the infection process before 181 symptom onset.

182 Since HCA degradation genes were highly expressed when *R. solanacearum* infected 183 plants at cool temperatures (Meng, Jacobs and Allen, unpublished), we also quantified the 184 virulence of the Δfcs mutant in a growth chamber at 24°C day and 19°C night (Fig 3C). 185 Under these cooler conditions, the Δfcs mutant also displayed a virulence defect.

HCA degradation is not required for *R. solanacearum* growth in plant-associated environments.

188 We hypothesized that HCA degradation contributes to *R. solanacearum* virulence by 189 providing the bacterium with a carbon source in the competitive and nutrient-limited 190 niches in and around plants. Plant roots exude HCAs into the rhizosphere, and HCAs 191 comprise up to 10% of the water-soluble carbon in soil (Smolander et al., 2005). Thus, the 192 ability to use HCAs as a carbon source could provide bacteria with a competitive edge in 193 the soil. We asked whether HCA degradation increased growth of R. solanacearum in water-194 soluble potting soil extract and in root exudate from sterile tomato seedlings. The Δfcs mutant grew as well as its wild type parent in both substrates (Fig. 4A-B). However, sterile 195 196 tomato seedlings may produce less HCAs than mature plants with a diverse microbiome 197 since pathogens induce production and release of HCAs into the rhizosphere (Neumann 198 and Römheld, 2007). HCAs chelate and transport metals in the xylem sap, and 199 concentrations of HCA conjugates increase in grapevines infected with *Xylella* (Ishimaru et 200 al., 2011; Wallis and Chen, 2012). Therefore we asked whether HCA degradation provides a 201 growth benefit to *R. solanacearum* in xylem sap. Xylem sap was harvested by detopping 202 healthy tomato plants and allowing root pressure to exude the sap. The sap was filter 203 sterilized and used as a growth substrate for WT, Δfcs , and $\Delta fcs+fcs$ (complemented) 204 bacteria. HCA degradation ability did not affect growth of any strain in healthy xylem sap 205 (Fig. 4C). Because *R. solanacearum* infections induce expression of tomato phenolic 206 biosynthesis genes (Ishihara et al., 2012; Mitra, Milling, and Allen unpublished), we 207 hypothesized that xylem sap from infected plants contains higher HCA concentrations that

Page 11 of 51

Lowe, Tiffany - MPMI

208 would benefit growth of the WT strain. However, we detected no differences in growth 209 between WT and Δfcs when they were grown in sap harvested from plants infected with 210 WT or the Δfcs mutant (data not shown). Because the Δfcs mutant grew normally on these 211 substrates, we infer that HCAs were not significant sources of carbon or present in 212 sufficient concentrations to inhibit bacterial growth.

213 HCA degradation contributes to colonization of tomato roots.

214 Studies of *R. solanacearum* growth in potting soil extract, root exudate from sterile 215 seedlings, and xylem sap cannot reflect the complex process of invading and multiplying in 216 hosts. Therefore, we transitioned to whole-plant assays. To measure the overall fitness of 217 the Δfcs mutant in a naturalistic infection, we used a competition assay where plants were 218 co-inoculated with a 1:1 suspension of WT and Δfcs mutant bacteria using the soil-soaking 219 method. At the first sign of wilt symptoms, we quantified the population size of each strain 220 in the midstem (Fig. 5C). With a median competitive index (CI) of 0.46, the Δfcs mutant was 221 significantly less fit than WT bacteria (Wilcoxon signed rank test; P < 0.0001). The WT strain 222 outcompeted the Δfcs mutant by 2.2-fold. This assay requires strains to compete during 223 several stages of the *R. solanacearum* infection cycle: survival in bulk soil and colonization 224 of host rhizosphere, roots, and stems. The cumulative effects of these competitive 225 interactions are assessed by comparing population sizes of the two strains in tomato stems. 226 The observed reduced competitive fitness of the Δfcs mutant indicates that HCA 227 degradation contributes to at least one stage of the *R. solanacearum* infection cycle. 228 To more narrowly investigate the role of HCA degradation in early stages of

229 infection, we individually soil-soak inoculated tomato plants with gentamicin-marked WT

Molecular Plant-Microbe Interactions "First Look" paper • http://dx.doi.org/10.1094/MPMI-09-14-0292-FI • posted 11/25/2014 This paper has been peer reviewed and accepted for publication but has not yet been copyedited or proofread. The final published version may differ.

and Δfcs bacteria and quantified population sizes of the strains in surface-sterilized roots (Fig. 5A). At 3 dpi, the population sizes of the Δfcs mutant were lower than those of WT bacteria in roots (*P*<0.0094, *t*-test), but by 6 dpi, the population size of the mutant caught up to wildtype levels. These results indicate that HCA degradation contributed significantly to *R. solanacearum*'s ability to enter and/or grow within the root.

235 To investigate the role of HCA degradation when the bacterium is in tomato stems, 236 we used a two-pronged approach. First we quantified population sizes of the WT and Δfcs 237 strains in the midstem stem after individual soil-soak inoculations (Fig 5B). At 3 dpi, few 238 stems were colonized with detectable levels of bacteria. At 6 dpi, the average stem population size of WT bacteria was slightly, but insignificantly, higher than that of the Δfcs 239 240 mutant. We next used an *in planta* competition assay that can reveal subtle colonization 241 defects that are missed in individual colonization assays (Yao and Allen, 2006; Macho et al., 242 2010). For this assay, 2,000 CFU of reciprocally-marked WT and Δfcs bacteria were co-243 inoculated into tomato plants via a cut petiole. At symptom onset, the midstem population 244 size of each strain was determined by grinding stem tissue and dilution plating. The 245 population size of the WT strain was slightly larger than that of the Δfcs mutant in this instem competition assay, but the two strains were not significantly different. Overall, 246 247 colonization assays indicated that HCA degradation may improve stem colonization and 248 showed that HCA degradation contributed significantly to the bacterium's ability to 249 colonize roots.

R. solanacearum HCA degradation does not detectably affect quantity or distribution
 of lignin in susceptible tomato stems.

Page 13 of 51

252 As phenylpropanoids, HCAs are precursors to many plant physical defenses, such as 253 diferulate cross-links in primary cell walls and lignin in secondary cell walls. Plant hosts 254 often respond to pathogens by increasing biosynthesis and deposition of phenylpropanoids 255 (Dixon and Paiva, 1995). Previous studies found that bacterial wilt-resistant tomato plants 256 express phenylpropanoid biosynthesis genes early during *R. solanacearum* infections 257 (Vanitha et al., 2009). We hypothesized that HCA degradation by the pathogen may reduce 258 or prevent lignin formation by decreasing the pool of lignin precursors (HCAs). To test this 259 prediction, we used the acetyl bromide assay to measure gross lignin amounts in whole 260 stems from healthy tomato plants and from plants infected with WT or Δfcs bacteria. The lignin content in stems of the wilt-susceptible Bonny Best cultivar did not increase in 261 262 response to infection with either *R. solanacearum* strain (Fig. 6A). Analysis of whole stems 263 could overlook variation in lignin distribution between conditions, but a histopathological 264 analysis of stem cross sections using the lignin-specific stain phloroglucinol revealed that 265 lignin was similarly distributed in all samples, mainly around the xylem vessels in the 266 vascular bundles (Fig. 6B-D). This result suggested that *R. solanacearum's* HCA degradation 267 pathway does not detectably alter the amount or the distribution of host lignin, at least under the conditions tested. 268

These experiments do not determine if HCA degradation affects the amount of
diferulate cross-links in the primary cell wall. Several plant pathogens with large
repertoires of cell-wall degrading enzymes use feruloyl esterases to cleave ferulate from
cell wall sugars (DiGuistini et al., 2011; Hassan and Hugouvieux-Cotte-Pattat, 2011;
Balcerzak et al., 2012). It is possible that *R. solanacearum* encounters diferulate bridges

274 when entering roots or when degrading pit membranes between xylem vessels. Therefore, 275 we tested for ferulovl esterase activity by growing WT strain GMI1000 on an HCA-276 glucoside analog, ethyl-ferulate. The strain could not use ethyl-ferulate as a sole carbon 277 source (data not shown), which indicates a lack of feruloyl esterase activity. To test 278 whether HCA degradation helps *R. solanacearum* pass through pit membranes and spread 279 in tomato stem, wildtype and Δfcs mutant strains were directly inoculated into the xylem of 280 four week old tomato plants via a cut petiole. At 6-10 days after inoculation, bacterial 281 population sizes were quantified by grinding and dilution plating stem tissue harvested at 282 the point of inoculation and distal sites (3 and 6 cm above the point of inoculation). There 283 were no strain-to-strain differences in population sizes in the distal stem (data not shown). 284 These results suggest that HCA degradation does not measurably contribute to R. 285 solanacearum spread in tomato stems.

286 HCA degradation protects *R. solanacearum* from caffeate and *p*-coumarate toxicity.

287 HCAs are broadly toxic to microbes. They can directly disrupt membrane integrity, and they are converted to reactive guinones under oxidative conditions, such as after an 288 289 ROS burst during infection of a eukaryotic host (Li and Steffens, 2002; Fitzgerald et al., 290 2004). We hypothesized that *R. solanacearum* uses its HCA degradation pathway to 291 detoxify these potentially lethal chemicals. Using a minimum inhibitory concentration 292 (MIC) growth assay, we compared growth of WT and Δfcs bacteria in the presence of 293 increasing concentrations of the three HCAs: *p*-coumarate, caffeate, and ferulate. For WT, 294 the MICs of the *p*-coumarate and caffeate were $1,500 \mu$ M, and the MIC of ferulate was 3,000295 μ M (Fig. 7). The growth of the Δfcs mutant was dramatically reduced relative to growth of

296 the WT strain at sub-MIC concentrations of both *p*-coumarate and caffeate with the Δfcs 297 mutant showing a significant growth defect in as little as 23 μ M of *p*-coumarate and 298 caffeate. The Δfcs mutant suffered near-complete growth inhibition at 375 µM p-coumarate 299 even though WT bacteria were unaffected by this concentration (Fig. 7A and B). In contrast, 300 there was no difference in growth between WT and Δfcs bacteria at any ferulate 301 concentration (Fig. 7C). Adding a wild-type copy of the *fcs* operon to the mutant restored 302 full wild-type levels of *p*-coumarate and caffeate tolerance to the complemented strain. 303 Together, these results suggested that HCA degradation protects *R. solanacearum* from 304 toxicity of caffeate and *p*-coumarate but not ferulate.

305 Discussion

Plant-associated bacteria experience a complex cocktail of secondary metabolites
produced by their eukaryotic hosts. Some of these compounds may provide nutrition, while
many are inhibitory or toxic. We found that the ability to degrade a group of such
compounds, the HCAs, is a quantitative virulence factor for *R. solanacearum*. More specific
analyses revealed that HCA degradation contributes to bacterial wilt pathogenesis, possibly
by protecting the pathogen from inhibition by toxic HCAs during root colonization.

312 Several lines of evidence support our model that HCA degradation contributes to *R*. 313 solanacearum fitness at early stages of disease. First, we found that the HCA degradation 314 and β -ketoadipate pathways are found predominantly in soil-inhabiting bacteria. In 315 contrast, we did not detect conservation of HCA degradation genes in the xylem-colonizing 316 bacteria *Clavibacter michiganensis, Xylella fastidiosa, Dickeya dadantii*, or *Erwinia* 317 *amylovora*. Second, the virulence defect of the Δfcs mutant includes a delay in the first

Page 16 of 51

Lowe, Tiffany - MPMI

318 appearance of symptoms. The delay in symptom onset likely results from this mutant's 319 slower colonization of host roots. Surprisingly, the delay in root colonization by the Δfcs 320 mutant did not result in smaller eventual population sizes in the stems of infected plants. 321 This suggests that once the pathogen gains entry to xylem vessels, a strain unable to 322 degrade HCAs can grow to the same final density as its wild-type parent. Thus, HCA 323 degradation appears to be most useful to *R. solanacearum* in host roots and rhizospheres. 324 Our *in vitro* inhibition assay demonstrates that the mutant is more susceptible to 325 toxicity of certain HCAs. Although the HCA concentrations required for growth inhibition in 326 *vitro* are 10 to 100-fold higher than concentrations measured *in planta*, concentrations of 327 these compounds in the xylem of roots and stems may be locally high where phenolics are 328 released by sentinel phenolic-storing-cells (Beckman, 2000; Alvarez et al., 2008; Mandal 329 and Mitra, 2008; Wallis and Chen, 2012). Additionally, the metabolic state of R. 330 solanacearum cells affected their susceptibility to HCAs; HCAs were more inhibitory when 331 *R. solanacearum* was grown in glucose minimal media than when grown in succinate 332 minimal media (data not shown). Moreover, it takes less HCA to inhibit microbial growth 333 when HCAs are present in mixtures than when only one HCA is present (Harris et al., 2010). 334 *R. solanacearum* cells likely encounter mixtures of HCAs and other antimicrobial 335 compounds when infecting plants. It is therefore possible that the effective inhibitory 336 concentrations of caffeate and *p*-coumarate are lower in the complex chemical environment of an infected plant than in a single-chemical *in vitro* MIC assay. 337 338 Surprisingly, HCA degradation ability did not affect the toxicity of ferulate. *R.* 339 *solanacearum* may have an *fcs*-independent pathway that specifically degrades ferulate,

Page 17 of 51

Lowe, Tiffany - MPMI

340 although this seems unlikely because the Δfcs mutant could not grow on ferulate. 341 Alternatively, *R. solangearum* could have a drug efflux pump that is highly effective at 342 removing ferulate but less active on caffeate and *p*-coumarate. The drug efflux pumps 343 encoded by *dinF* and *acrA* are very important for strain K60's virulence on tomato (Brown 344 et al., 2007). The *acrA* mutant had heightened susceptibility to caffeate toxicity, but other 345 HCAs were not tested. Strain K60 lacks the HCA degradation pathway, so it would be 346 interesting to determine if drug efflux pumps also protect other *R. solanacearum* strains from toxicity of caffeate and other HCAs. 347

348 Our virulence studies used a single strain, GMI1000, but the capacity to degrade HCAs is genetically well conserved across the *R. solanacearum* species complex. Although 349 350 bioinformatic analysis accurately predicted the ability of strains to grow on various HCA 351 compounds 83% of the time, several strains did not grow on all predicted HCA carbon 352 sources. These disparities demonstrate that predictions based on genomic analysis require 353 functional validation, especially to confirm enzyme substrate specificity (Airola et al., 2014). 354 The multi-strain screen for HCA degradation ability revealed several surprising results. 355 Although CFBP2957 and Molk2 grew on ferulate, they did not grow on ferulate degradation 356 intermediates. It is possible that higher sensitivity to toxicity of vanillin and vanillate 357 prevented these strains from growing. Alternatively, vanillin and vanillate may not induce 358 expression of *vdh* and *vanAB* genes as these compounds appear to do in most *R*. 359 solanacearum strains. Pseudogenization of the fcs gene in the Race 3 biovar 2 strains 360 (UW491 and UW551) appears to prevent this strain from growing on most metabolites

361 upstream of protocatechuate. This is in contrast to strain GMI1000 where deletion of *fcs*362 did not affect growth on any compounds besides HCAs.

363 Although *R. solanacearum* expresses its HCA degradation genes in stem xylem 364 vessels during tomato pathogenesis, these genes are only expressed at moderate levels 365 (Jacobs et al., 2012). It is not surprising that HCA degradation genes were not identified in 366 our previous IVET screen for root exudate induced genes because that study used R. solanacearum strain K60, which has lost HCA degradation ability (Colburn-Clifford and 367 Allen, 2010). Transcriptional analysis could be used to compare expression of HCA 368 369 degradation genes at different stages in the *R. solanacearum* life cycle, particularly in the rhizosphere. Phenolics in root exudate are chemoattractants for many rhizosphere 370 371 bacteria, including Agrobacterium tumefaciens (Mandal et al., 2010). Chemotaxis allows R. solanacearum to locate host plants, but it remains to be determined whether root-exuded 372 phenolics serve as chemoattractants (Yao and Allen, 2006). 373

374 Plant phenolics influence expression of virulence genes in many plant mutualists 375 and pathogens. Ferulate and other phenolics induce expression of Agrobacterium vir genes, 376 and flavonoids induce *Rhizobium nod* genes, both of which are required for association with 377 plants (Bhattacharya et al., 2010). Expression of the Dickeya dadantii type III secretion 378 genes is induced by the phenolics *o*-coumarate and *trans*-cinnamate and repressed by *p*-379 coumarate (Li et al 2009 and Yang et al 2008). We cannot rule out the possibility that the 380 virulence defect of the Δfcs mutant is due to HCA-mediated repression of the pathogen's 381 type III secretion system, although such repression cannot be complete because the Δfcs 382 mutant still triggers a hypersensitive response in the non-host tobacco (data not shown).

Page 19 of 51

Lowe, Tiffany - MPMI

383 In response to pathogen attack, plants can reinforce cell walls with lignin, which is 384 an HCA polymer. Although we didn't identify an obvious difference in stem lignin in 385 susceptible tomato after *R. solanacearum* infections, we cannot rule out subtle but 386 biologically important differences that would be undetectable in our gross analyses. 387 Moreover, this trait may play an important role in resistant tomato cultivars. A previous 388 study observed increased lignification in response to *R. solanacearum* infections in the 389 quantitatively wilt-resistant tomato cv. LS-89, but not in susceptible tomato cv. Ponderosa 390 (Ishihara et al., 2012). Histopathological studies of resistant and susceptible tomato found 391 that *R. solanacearum* colonized fewer xylem vessels in wilt-resistant varieties (Grimault et 392 al., 1994; Rahman et al., 1999). It is therefore possible that physical barriers to pathogen 393 spread may be a component of tomato resistance to bacterial wilt. 394 Taken together, our results indicate that *R. solanacearum*'s ability to enzymatically

395 disarm HCAs contributes to the success of this widespread pathogen. Pathogens have 396 adopted multiple strategies to evade plant defense compounds. *Pseudomonas syringae* uses 397 type III effectors to manipulate plant phenylpropanoids (Truman et al., 2006). Many plant 398 pathogens protect themselves with drug efflux pumps, while others enzymatically degrade 399 the plant defense compounds pisatin, tomatine, and HCAs (Tegtmeier and VanEtten, 1982; 400 Tegos et al., 2002; Brown et al., 2007; Seipke and Loria, 2008; Michielse et al., 2012). Our 401 results support a general model that root-infecting pathogens encounter toxic 402 concentrations of HCAs, and that degradation of these defenses is important for pathogenic 403 success.

404 Materials and Methods

405 **Cultures and stock solutions**

406 The bacterial strains and plasmids used in this study are described in Table 1. E. coli 407 was grown in Luria-Bertani (LB) medium at 37°C. R. solanacearum was grown in CPG broth or TZC plates at 28 °C (Kelman, 1954). When appropriate, the antibiotics gentamicin (15 408 409 mg/L), kanamycin (25 mg/L), and ampicillin (50 m/L) were added. Boucher's minimal 410 medium (BMM) buffered with 10 mM MES (2-(*N*-morpholino) ethanesulfonic acid) pH 5.5 411 or 7.0 was used as a minimal medium (Boucher et al., 1985). For sampling from the soil or 412 roots, *R. solanacearum* was plated on modified SMSA semi-selective medium (10 g/L 413 peptone, 5 ml/L glycerol, 1 g/L casamino acids, 2.5 mg/L crystal violet, 2.5 mg/L TZC [tetrazolium chloride], 13 mg/L bacitracin, 0.3 mg/L penicillin, 2.5 mg/L chloramphenicol, 414 415 25 mg/L cycloheximide) (Engelbrecht, 1994). Stock solutions of phenolic compounds were 416 prepared in DMSO. Chemicals were from Sigma-Aldrich, Fisher Scientific, or Difco Laboratories. 417

418 A plate assay was used to detect HCA degradation ability in 20 R. solanacearum 419 isolates. BMM MES pH 7.0 plates were supplemented with 1 mM succinate, ferulate, p-420 coumarate, vanillin, vanillate, *p*-hydroxybenzoate, or 5 mM protocatechuate. Compound 421 concentration was chosen empirically as there was a trade-off between compound toxicity 422 at high concentrations and minimal bacterial growth at low concentrations. To assess 423 growth, 2 μ l of a dense overnight culture of each strain was spotted onto the plates. After 424 incubation at 28 °C for three to five days, growth of the strains on each substrate was 425 assessed relative to growth on BMM plates without supplemented carbon. In several cases, 426 plate growth phenotypes were indeterminate or contradicted predictions from genomic

427	data. So, growth was further tested by culturing these strains for 48 hr in liquid BMM with
428	the relevant carbon source and quantifying cell density by dilution plating.
429	Plant growth conditions
430	Wilt-susceptible tomato plants (cv. Bonny Best) were grown in Sunshine Redimix
431	professional growing mix at 28 °C in a climate controlled growth chamber with a 12 hr
432	day/ 12 hr night cycle. To test virulence during cool conditions, plants were grown in a
433	climate controlled chamber with a 24 day/19 $^\circ$ C night cycle. Plants were watered with
434	Hoagland solution.
435	Genomic analysis of <i>R. solanacearum</i> species complex and identification of HCA
436	degradation gene homologs
437	The phylogenetic tree was designed around a matrix of genomic distances obtained
438	using the Maximum Unique Match index (MUMi) algorithm (Deloger et al., 2009). MUMi
439	values were computed from pairwise genome comparisons made with MUMMer 3.0 (Kurtz
440	et al., 2004). The distances were then clustered together into a tree using the neighbor-
441	joining method (Saitou and Nei, 1987).
442	We identified homologs of the GMI1000 and UW551 HCA degradation pathway
443	using the OMA algorithm with translated coding sequences from the genomes of the other
444	<i>R. solanacearum</i> isolates (Altenhoff et al., 2011).
445	Strain construction
446	The Δfcs strain was created using a <i>sacB</i> suicide vector designed to precisely excise
447	the fcs ORF. Briefly, we amplified \sim 1 kb regions directly upstream (fcsKOupF: 5'-

448 CTCGACGATGCGGACCTG-3'; fcsKOupR: 5'-GACAGCGACCTCGCATCAG-3') and downstream 21

449	of the <i>fcs</i> ORF (fcsKOdwnF: 5'-ctcatgcgaggtcgctgtcGAGTGTTGAGCGGGGCC-3'; fcsKOdwnR:
450	5'-GGAAGGCGAATTCGAGCG-3') by PCR, fused the fragments by splice by overlap extension
451	PCR (SOE-PCR) (Heckman and Pease, 2007), and blunt-end ligated them into the pCR-blunt
452	subcloning vector (Life Technologies). This knockout construct was transferred by
453	restriction digestion and ligation to the <i>sacB</i> vector pUFR80 to create pUFR80-fcsKO
454	(Castañeda et al., 2005). R. solanacearum strain GMI1000 (WT) was transformed with
455	pUFR80-fcsKO by electroporation and plated on kanamycin media to select for
456	merodiploids that were sucrose sensitive and Kan ^R . A clone was then counter-selected on
457	CPG+5% sucrose to select for excision of the <i>sacB</i> -containing vector backbone. This process
458	either restored the wildtype genotype or yielded a markerless deletion of the <i>fcs</i> ORF.
459	Colony PCR using fcsKOupF and fcsKOdwnR primers was used to screen for loss of the fcs
460	ORF.
461	A miniTn7 vector was used to complement the Δfcs strain (Choi et al., 2005). The
462	miniTn7 transposon integrates into the selectively neutral <i>att</i> site downstream of <i>glmS</i> . We
463	amplified the 5.6 kb putative operon encompassing 500 bp upstream of <i>fca</i> , the <i>fca</i> ORF, the
464	vdh ORF and the fcs ORF using primers fcsoperonF (5'-TGCACCAGGACCAATACCTC-3') and
465	fcsoperonR (5'-CTCAACGTGTTCCCCATCCA-3'). The resulting PCR product was subcloned

into pCR-blunt and transferred by restriction enzyme digestion and ligation into pUC18t-

467 miniTn7-Gm to create pTn7fcsComp. The $\Delta fcs R$. solanacearum strain was transformed

with pMiniTn7fcsComp and the helper vector pTNS1 encoding the transposase TnsABC+D
and plated on gentamicin media. Complementation was confirmed by restoration of the
ability to grow on HCAs.

Molecular Plant-Microbe Interactions "First Look" paper • http://dx.doi.org/10.1094/MPMI-09-14.0292-FI • posted 11/25/2014 This paper has been peer reviewed and accepted for publication but has not yet been copyedited or proofread. The final published version may differ.

Page 23 of 51

Lowe, Tiffany - MPMI

471 To create antibiotic marked strains for colonization and competition assays,
472 GMI1000 and the Δ*fcs* strain were transformed with the chromosomal insertion vectors
473 pRCG-GWY or pRCK-GWY carrying gentamicin or kanamycin cassettes, respectively
474 (Monteiro et al., 2012).

475 Virulence assay

To assess virulence following soil soak inoculation, 17- to 21-day old plants with unwounded roots were inoculated by pouring bacterial suspensions into the soil to a final concentration of 1 x 10⁸ CFU/g soil (Tans-Kersten et al., 1998). Symptoms on each plant were rated daily using a disease index scale of 0-4 corresponding to wilt severity: 0, asymptomatic plants; 1, less than 25%; 2, less than 50%; 3, less than 75%; and 4, up to 100% leaves wilted.

482 **Colonization and competition assays**

483 To assess colonization ability of individual strains, plants were soil soak inoculated 484 with either WT-Gm or Δfcs -Gm. At 3 and 6 days after inoculation, bacterial populations 485 were determined in surface-sterilized root and midstem stem tissue. To surface sterilize 486 the roots, soil was removed by gentle shaking and washing. Then roots were swirled in a 10% bleach solution for 15 sec and rinsed three times in successive water baths to remove 487 488 remaining bleach. Roots were sectioned into evenly distributed slices totaling 0.3 g. From 489 the same plants, a 0.1 g midstem stem slice was sampled. Tissue was ground in water with 0.28 mm metal beads using a homogenizer (MoBio). Stem grinding required 2 cycles, and 490 491 root grinding required 3 cycles of 2200 rpm for 1.5 min with a 4 min rest between cycles.

Homogenized root and stem tissue were dilution plated onto SMSA and CPG withgentamicin, respectively.

494 A competition assay was used to investigate subtler differences in stem colonization 495 ability (Yao and Allen, 2006). For soil soak inoculations, plants were inoculated with a 1:1 496 mixture of antibiotic-marked WT: Δfcs bacteria totaling 1 x 10⁸ CFU/g soil. Marker 497 swapping was used to ensure that competitive fitness differences were not caused by the 498 antibiotic resistance marker: thus a set of plants were inoculated with a WT-Gm+ Δfcs -Km 499 mixture and another set were inoculated with a WT-Km+ Δfcs -Gm mixture. Antibiotic 500 markers did not significantly impact the fitness of either strain (Fig. S1). At the first sign of wilt symptoms (disease index = 1), plants were harvested and population sizes of each 501 502 strain in the stem were determined by grinding and dilution plating on selective media. 503 Population size was normalized to initial inoculum of each strain. Then, competitive index 504 (CI) was calculated by dividing the normalized Δfcs population size by the normalized WT 505 population size from the same plant. For cut-petiole inoculations, bacteria were directly 506 introduced into the stem by placing a 2 µl drop of bacterial suspension onto a freshly cut 507 petiole. Each plant was inoculated with 4,000 cells in a 1:1 mixture of marked WT and Δfcs 508 bacteria.

509 Growth in xylem sap, root exudate, and potting soil extract

510 Xylem sap was collected from healthy and soil soak inoculated plants displaying the 511 first signs of symptoms, as previously described (Jacobs et al., 2012). Plants were detopped 512 with a sharp blade, and sap was allowed to pool on the stump by root pressure. The first 513 drop was discarded to avoid contamination by cell debris, and the stump was rinsed with

water and blotted dry. Sap was only collected for 30 minutes to avoid damage-responseinduced changes in sap composition. Samples were flash-frozen and kept at -80°C until use.
Growth of strains on 0.2 uM filter-sterilized xylem sap, root exudate was measured in a
plate reader (Bio-Tek). Overnight cultures were washed and adjusted to OD_{600nm} of 1.0. In a
half-area 96-well plate (Corning), 45 µl of each growth substrate was combined with 5 µl of
bacterial suspensions. Optical density was measured hourly until growth plateaued. Each
experiment was repeated twice.

Root exudate was collected as described (Yao and Allen, 2006). Briefly, seeds were
sterilized and germinated on 1% water agar plates in the dark for 3 days. Sterile roots were
transferred into a 50 ml conical tube containing 5 ml of BMM with 10 mM MES pH 7.0.
Tubes were incubated in the dark for 24 hr, and root exudate was used immediately as
previous studies reported loss of potency with time.

526To collect water-soluble potting soil extract, 1 g of potting soil was suspended in 50527ml of distilled water in a 50 ml conical tube and incubated horizontally with shaking for 2528hr at room temperature (Smolander et al., 2005). Filtered potting soil extract was used529immediately. Dense overnight cultures were washed, and 0.5 µl of the cell suspension was530inoculated into 5 ml of potting soil extract. Cell density was determined periodically by531dilution plating.

532

2 Lignin quantification and visualization

533 Twenty-one day-old tomato plants were left healthy or inoculated by pouring WT or 534 Δfcs bacteria into the soil to a final concentration of 1 x 10⁸ CFU/g soil. Total stem was 535 harvested 3, 6, and 9 days after inoculation and desiccated, yielding approximately 30 mg

dry weight/plant. Total lignin was quantified by the spectroscopic acetyl bromide assay
(Fukushima and Hatfield, 2004). Wood pulp inulin was used as a lignin standard. Lignin in
cross-sections of tomato stems was stained by phloroglucinol:HCl (Nakano and Meshitsuka,
1992).

540 **Growth inhibition assay**

541A growth inhibition assay modified from the standard minimum inhibitory542concentration (MIC) assay was used to test the toxicity of HCAs (Brown et al., 2007). BMM543MES pH 5.5 +10 mM succinate supplemented with 23-3000 μM of ferulate, caffeate, or *p*-544coumarate or with no inhibiting compound was inoculated with bacterial strains to 1 x 10⁵545CFU/ml final concentration. After incubating strains at 28 °C with shaking, cell density was546measured by optical density in a Bio-Tek plate reader. Growth of strains in each condition547was calculated relative to growth of the WT strain without inhibitory HCAs.

548 Acknowledgements

549 The authors gratefully acknowledge Paul Weimer for help with lignin analysis, 550 Mehdi Kabbage for help with microscopy, and Frederique van Gijsegem, Devanshi 551 Khokhani, and Philippe Prior for valuable discussions. We thank Brianna Fochs for 552 technical help. This research was supported by the USDA-ARS Floral and Nursery Crops 553 Research Initiative and the UW-Madison College of Agricultural and Life Sciences. TML was 554 supported by NIH National Research Service Award T32 GM07215 and by a Agriculture and Food Research Initiative Competitive Grant from the USDA National Institute of Food 555 556 and Agriculture.

557 Author Contributions

- 558 T. Lowe designed most experiments and analyzed data. F. Ailloud constructed the
- whole-genome phylogenetic tree and analyzed the genetic conservation of the HCA
- 560 degradation pathway. C. Allen advised T. Lowe in experimental design and analysis. All
- authors participated in drafting the manuscript and approved of the final version for
- 562 submission.

563 Literature Cited

- Abdelkafi, S., Sayadi, S., Gam, A., Ben, Z., Casalot, L., and Labat, M. 2006. Bioconversion of
 ferulic acid to vanillic acid by *Halomonas elongata* isolated from table-olive
 fermentation. FEMS Microbiol. Lett. 262:115-120.
 - Airola, M.V., Tumolo, J.M., Snider, J., and Hannun, Y.A. 2014. Identification and biochemical characterization of an acid sphingomyelinase-like protein from the bacterial plant pathogen *Ralstonia solanacearum* that hydrolyzes ATP to AMP but not sphingomyelin to ceramide. PLoS ONE 9:e105830.
 - Altenhoff, A.M., Schneider, A., Gonnet, G.H., and Dessimoz, C. 2011. OMA 2011: orthology inference among 1000 complete genomes. Nucleic Acids Res. 39:D289-D294.
 - Alvarez, S., Marsh, E.L., Schroeder, S.G., and Schachtman, D.P. 2008. Metabolomic and proteomic changes in the xylem sap of maize under drought. Plant Cell Environ. 31:325-340.
 - Balcerzak, M., Harris, L.J., Subramaniam, R., and Ouellet, T. 2012. The feruloyl esterase gene family of *Fusarium graminearum* is differentially regulated by aromatic compounds and hosts. Fungal Biol. 116:478-488.
 - Beckman, C.H. 2000. Phenolic-storing cells: keys to programmed cell death and periderm formation in wilt disease resistance and in general defence responses in plants? Physiol. Mol. Plant Path. 57:101-110.
 - Bhattacharya, A., Sood, P., and Citovsky, V. 2010. The roles of plant phenolics in defence and communication during *Agrobacterium* and *Rhizobium* infection. Mol. Plant Pathol. 11:705-719.
 - Boucher, C., Barberis, P., Trigalet, A., and Demery, D. 1985. Transposon mutagenesis of *Pseudomonas solanacearum*: isolation of Tn5-induced avirulent mutants. J. Gen. Microbiol. 131:2449-2457.
- Brown, D.G., Swanson, J.K., and Allen, C. 2007. Two host-induced *Ralstonia solanacearum*genes, *acrA* and *dinF*, encode multidrug efflux pumps and contribute to bacterial wilt
 virulence. Appl. Environ. Microbiol. 73:2777-2786.
- Campillo, T., Renoud, S., Kerzaon, I., Vial, L., Baude, J., Gaillard, V., Bellvert, F., Chamignon, C.,
 Comte, G., and Nesme, X. 2014. Analysis of hydroxycinnamic acid degradation in
 Agrobacterium fabrum reveals a coenzyme A-dependent, beta-oxidative
 deacetylation pathway. Appl. Env. Microbiol. 80:3341-3349.

567

568

569 570

571 572

573

574

575 576

577 578

579

580

581

582

583 584

585

595	Campos, L., Lisón, P., López-Gresa, M.P., Rodrigo, I., Zacarés, L., Conejero, V., and Bellés, J.M.
596	2014. Transgenic tomato plants overexpressing tyramine N-
597	hydroxycinnamoyltransferase exhibit elevated hydroxycinnamic acid amide levels
598	and enhanced resistance to Pseudomonas syringae. Mol. Plant-Microbe Interact.
599	27:1159-1169.

- Cao, Y., Tian, B., Liu, Y., Cai, L., Wang, H., Lu, N., Wang, M., Shang, S., Luo, Z., and Shi, J. 2013.
 Genome sequencing of *Ralstonia solanacearum* FQY_4, isolated from a bacterial wilt
 nursery used for breeding crop resistance. Genome Announc. 1:e00125-00113.
- Castañeda, A., Reddy, J.D., El-Yacoubi, B., and Gabriel, D.W. 2005. Mutagenesis of all eight *avr* genes in *Xanthomonas campestris* pv. *campestris* had no detected effect on
 pathogenicity, but one *avr* gene affected race specificity. Mol. Plant-Microbe Interact.
 18:1306-1317.
 - Choi, K.-H., Gaynor, J.B., White, K.G., Lopez, C., Bosio, C.M., Karkhoff-Schweizer, R.R., and Schweizer, H.P. 2005. A Tn7-based broad-range bacterial cloning and expression system. Nat. Methods 2:443-448.
 - Colburn-Clifford, J., and Allen, C. 2010. A *cbb3*-type cytochrome C oxidase contributes to *Ralstonia solanacearum* R3bv2 growth in microaerobic environments and to bacterial wilt disease development in tomato. Mol. Plant-Microbe Interact. 23:1042-1052.
 - Deloger, M., El Karoui, M., and Petit, M.A. 2009. A genomic distance based on MUM indicates discontinuity between most bacterial species and genera. J. Bacteriol. 191:91-99.
- DiGuistini, S., Wang, Y., Liao, N.Y., Taylor, G., Tanguay, P., Feau, N., Henrissat, B., Chan, S.K.,
 Hesse-Orce, U., and Alamouti, S.M. 2011. Genome and transcriptome analyses of the
 mountain pine beetle-fungal symbiont *Grosmannia clavigera*, a lodgepole pine
 pathogen. Proc. Natl. Acad. Sci. U.S.A. 108:2504-2509.
 - Dixon, R.A., and Paiva, N.L. 1995. Stress-induced phenylpropanoid metabolism. Plant Cell 7:1085-1097.
 - Elphinstone, J.G. 2005. The current bacterial wilt situation: A global overview. Pages 9-28 in: Bacterial Wilt: The Disease and the *Ralstonia solanacearum* Species Complex, C. Allen, P. Prior, and A.C. Hayward, eds. American Phytopathological Society Press, St Paul.
 - Engelbrecht, M. 1994. Modification of a semi-selective medium for the isolation and quantification of *Pseudomonas solanacearum*. Bacterial Wilt Newsletter:3-5.
 - Fitzgerald, D., Stratford, M., Gasson, M., Ueckert, J., Bos, A., and Narbad, A. 2004. Mode of antimicrobial action of vanillin against *Escherichia coli, Lactobacillus plantarum* and *Listeria innocua*. J. Appl. Microbiol. 97:104-113.
 - Fry, S.C., Willis, S.C., and Paterson, A.E. 2000. Intraprotoplasmic and wall-localised formation of arabinoxylan-bound diferulates and larger ferulate coupling-products in maize cell-suspension cultures. Planta 211:679-692.
- Fukushima, R.S., and Hatfield, R.D. 2004. Comparison of the acetyl bromide
 spectrophotometric method with other analytical lignin methods for determining
 lignin concentration in forage samples. J. Agric. Food Chem. 52:3713-3720.
- Gabriel, D.W., Allen, C., Schell, M., Denny, T.P., Greenberg, J.T., Duan, Y.P., Flores-Cruz, Z.,
 Huang, Q., Clifford, J.M., Presting, G., González, E.T., Reddy, J., Elphinstone, J.,

607 608

609

610 611

612

613

614

615

620

621

622

623 624

625

626

627

628 629

630 631

632

639	Swanson, J., Yao, J., Mulholland, V., Liu, L., Farmerie, W., Patnaikuni, M., Balogh, B.,
640	Norman, D., Alvarez, A., Castillo, J.A., Jones, J., Saddler, G., Walunas, T., Zhukov, A., and
641	Mikhailova, N. 2006. Identification of open reading frames unique to a select agent:
642	Ralstonia solanacearum Race 3 biovar 2. Mol. Plant-Microbe Interact. 19:69-79.
643	Grimault, V., Gelie, B., Lemattre, M., Prior, P., and Schmit, J. 1994. Comparative histology of
644	resistant and susceptible tomato cultivars infected by <i>Pseudomonas solanacearum</i> .
645	Physiol. Mol. Plant Pathol. 44:105-123.
646	Harris, V., Jiranek, V., Ford, C.M., and Grbin, P.R. 2010. Inhibitory effect of hydroxycinnamic
647	acids on <i>Dekkera</i> spp. Appl. Microbiol. Biotechnol. 86:721-729.
648	Hassan, S., and Hugouvieux-Cotte-Pattat, N. 2011. Identification of two feruloyl esterases in
649	Dickeya dadantii 3937 and induction of the major feruloyl esterase and of pectate
650	lyases by ferulic acid. J. Bacteriol. 193:963-970.
651	Heckman, K.L., and Pease, L.R. 2007. Gene splicing and mutagenesis by PCR-driven overlap
652	extension. Nat. Protoc. 2:924-932.
653	Ishihara, T., Mitsuhara, I., Takahashi, H., and Nakaho, K. 2012. Transcriptome analysis of
654	quantitative resistance-specific response upon Ralstonia solanacearum infection in
655	tomato. PLoS ONE 7:e46763.
656	Ishimaru, Y., Kakei, Y., Shimo, H., Bashir, K., Sato, Y., Sato, Y., Uozumi, N., Nakanishi, H., and
657	Nishizawa, N.K. 2011. A rice phenolic efflux transporter is essential for solubilizing
658	precipitated apoplasmic iron in the plant stele. J. Biol. Chem. 286:24649-24655.
659	Jacobs, J.M., Babujee, L., Meng, F., Milling, A., and Allen, C. 2012. The <i>in planta</i> transcriptome
660	of Ralstonia solanacearum: conserved physiological and virulence strategies during
661	bacterial wilt of tomato. mBio 3:e00114-00112.
662	Kelman, A. 1954. The relationship of pathogenicity of <i>Pseudomonas solanacearum</i> to colony
663	appearance in tetrazolium medium. Phytopathol. 44:693-695.
664	Kim, D., Kim, S.W., Choi, K.Y., Lee, J.S., and Kim, E. 2008. Molecular cloning and functional
665	characterization of the genes encoding benzoate and <i>p</i> -hydroxybenzoate
666	degradation by the halophilic Chromohalobacter sp. strain HS-2. FEMS Microbiol.
667	Lett. 280:235-241.
668	Kurtz, S., Phillippy, A., Delcher, A.L., Smoot, M., Shumway, M., Antonescu, C., and Salzberg,
669	S.L. 2004. Versatile and open software for comparing large genomes. Genome Biol.
670	5:R12.
671	Lanoue, A., Burlat, V., Henkes, G.J., Koch, I., Schurr, U., and Röse, U.S. 2010. <i>De novo</i>
672	biosynthesis of defense root exudates in response to <i>Fusarium</i> attack in barley. New
673	Phytol. 185:577-588.
674	Li, L., and Steffens, J.C. 2002. Overexpression of polyphenol oxidase in transgenic tomato
675	plants results in enhanced bacterial disease resistance. Planta 215:239-247.
676	Li, Z., Wu, S., Bai, X., Liu, Y., Lu, J., Liu, Y., Xiao, B., Lu, X., and Fan, L. 2011. Genome sequence
677	of the tobacco bacterial wilt pathogen Ralstonia solanacearum. J. Bacteriol.
678	193:6088-6089.
679	Macho, A.P., Guidot, A., Barberis, P., Beuzón, C.R., and Genin, S. 2010. A competitive index
680	assay identifies several <i>Ralstonia solanacearum</i> Type III effector mutant strains with

682	Mandal, S., and Mitra, A. 2008. Accumulation of cell wall-bound phenolic metabolites and
683	their upliftment in hairy root cultures of tomato (Lycopersicon esculentum Mill.).
684	Biotechnol. Lett. 30:1253-1258.
685	Mandal, S.M., Chakraborty, D., and Dey, S. 2010. Phenolic acids act as signaling molecules in
686	plant-microbe symbioses. Plant Signal. Behav. 5:359-368.
687	Michielse, C.B., Reijnen, L., Olivain, C., Alabouvette, C., and Rep, M. 2012. Degradation of
688	aromatic compounds through the β -ketoadipate pathway is required for
689	pathogenicity of the tomato wilt pathogen <i>Fusarium oxysporum</i> f. sp. lycopersici. Mol.
690	Plant Pathol. 13:1089-1100.
691	Monteiro, F., Solé, M., Dijk, I.v., and Valls, M. 2012. A chromosomal insertion toolbox for
692	promoter probing, mutant complementation, and pathogenicity studies in Ralstonia
693	solanacearum. Mol. Plant-Microbe Interact. 25:557-568.
694	Mueller, W., and Beckman, C. 1984. Ultrastructure of the cell wall of vessel contact cells in
695	the xylem of tomato stems. Ann. Botany 53:107-114.
696	Nakaho, K., Hibino, H., and Miyagawa, H. 2000. Possible mechanisms limiting movement of
697	Ralstonia solanacearum in resistant tomato tissues. J. Phytopathol. 148:181-190.
698	Nakano, J., and Meshitsuka, G. 1992. The detection of lignin. Pages 23-32 in: Methods Lignin
699	Chemistry, S.Y. Lin and C.W. Dence, eds. Springer-Verlag, Berlin.
700	Naoumkina, M.A., Zhao, Q., GALLEGO-GIRALDO, L., Dai, X., Zhao, P.X., and Dixon, R.A. 2010.
701	Genome-wide analysis of phenylpropanoid defence pathways. Mol. Plant Pathol.
702	11:829-846.
703	Narbad, A., and Gasson, M.J. 1998. Metabolism of ferulic acid via vanillin using a novel CoA-
704	dependent pathway in a newly-isolated strain of <i>Pseudomonas fluorescens</i> .
705	Microbiology 144:1397-1405.
706	Neumann, G., and Römheld, V. 2007. The release of root exudates as affected by the plant
707	physiological status. Pages 23-72 in: The Rhizosphere Biochemistry and Organic
708	Substances at the Soil–Plant Interface, R. Pinton, Z. Veranini, and P. Nannipieri, eds.
709	CRC Press, New York.
710	Parke, D., and Ornston, L.N. 2003. Hydroxycinnamate (<i>hca</i>) catabolic genes from
711	Acinetobacter sp. strain ADP1 are repressed by HcaR and are induced by
712	hydroxycinnamoyl-coenzyme A thioesters. Appl. Environ. Microbiol. 69:5398-5409.
713	Peeters, N., Guidot, A., Vailleau, F., and Valls, M. 2013. <i>Ralstonia solanacearum</i> , a widespread
714	bacterial plant pathogen in the post-genomic era. Mol. Plant Pathol. 14:651-662.
715	Pérez-Pantoja, D., De la Iglesia, R., Pieper, D.H., and González, B. 2008. Metabolic
716	reconstruction of aromatic compounds degradation from the genome of the amazing
717	pollutant-degrading bacterium <i>Cupriavidus necator</i> JMP134. FEMS Microbiol. Rev.
718	32:736-794.
719	Plaggenborg, R., Overhage, J., Steinbüchel, A., and Priefert, H. 2003. Functional analyses of
720	genes involved in the metabolism of ferulic acid in <i>Pseudomonas putida</i> KT2440.
721	Appl. Microbiol. Biotechnol. 61:528-535.
722	Kahman, M.A., Abdullah, H., and Vanhaeke, M. 1999. Histopathology of susceptible and
723	resistant <i>Capsicum annuum</i> cultivars infected with <i>Ralstonia solanacearum</i> . J.
724	Phytopathol. 147:129-140.

725	Remenant, B., Babujee, L., Lajus, A., Médigue, C., Prior, P., and Allen, C. 2012. Sequencing of
726	K60, type strain of the major plant pathogen <i>Ralstonia solanacearum</i> . J. Bacteriol.
727	194:2742-2743.
728	Remenant, B., Cambiaire, JC.D., Cellier, G., Barbe, V., Medigue, C., Jacobs, J.M., Fegan, M.,
729	Allen, C., and Prior, P. 2011. Phylotype IV strains of Ralstonia solanacearum, R.
730	syzygii and the Blood Disease Bacterium form a single genomic species despite their
731	divergent life-styles. PLoS ONE 6:e24356.
732	Remenant, B., Coupat-Goutaland, B., Guidot, A., Cellier, G., Wicker, E., Allen, C., Fegan, M.,
733	Pruvost, O., Elbaz, M., Calteau, A., Salvignol, G., Mornico, D., Mangenot, S., Barbe, V.,
734	Médigue, C., and Prior, P. 2010. Genomes of three tomato pathogens within the
735	Ralstonia solanacearum species complex reveal significant evolutionary divergence.
736	BMC Genomics 11:379.
737	Romero-Silva, M.J., Méndez, V., Agullo, L., and Seeger, M. 2013. Genomic and functional
738	analyses of the gentisate and protocatechuate ring-cleavage pathways and related 3-
739	hydroxybenzoate and 4-hydroxybenzoate peripheral pathways in Burkholderia
740	xenovorans LB400. PloS ONE 8:e56038.
741	Saitou, N., and Nei, M. 1987. The neighbor-joining method: a new method for
742	reconstructing phylogenetic trees. Mol. Biol. Evol. 4:406-425.
743	Salanoubat, M., Genin, S., Artiguenave, F., Gouzy, J., Mangenot, S., Arlat, M., Billault, A.,
744	Brottier, P., Camus, J.C., Cattolico, L., Chandler, M., Choisne, N., Claudel-Renard, C.,
745	Cunnac, S., Demange, N., Gaspin, C., Lavie, M., Moisan, A., Robert, C., Saurin, W.,
746	Schiex, T., Siguier, P., Thebault, P., Whalen, M., Wincker, P., Levy, M., Weissenbach, J.,
747	and Boucher, C.A. 2002. Genome sequence of the plant pathogen <i>Ralstonia</i>
748	solanacearum. Nature 415:497-502.
749	Seipke, R.F., and Loria, R. 2008. Streptomyces scabies 87-22 possesses a functional
750	tomatinase. J. Bacteriol. 190:7684-7692.
751	Smolander, A., Loponen, J., Suominen, K., and Kitunen, V. 2005. Organic matter
752	characteristics and C and N transformations in the humus layer under two tree
753	species, <i>Betula pendula</i> and <i>Picea abies</i> . Soil Biol. Biochem. 37:1309-1318.
754	Tans-Kersten, J., Guan, Y., and Allen, C. 1998. Ralstonia solanacearum pectin methylesterase
755	is required for growth on methylated pectin but not for bacterial wilt virulence.
756	Appl. Environ. Microbiol. 64:4918-4923.
757	Tegos, G., Stermitz, F.R., Lomovskaya, O., and Lewis, K. 2002. Multidrug pump inhibitors
758	uncover remarkable activity of plant antimicrobials. Antimicrobial Agents and
759	Chemotherapy 46:3133-3141.
760	Tegtmeier, K., and VanEtten, H. 1982. The role of pisatin tolerance and degradation in the
761	virulence of <i>Nectria haematococca</i> on peas: a genetic analysis. Phytopathology
762	72:608-612.
763	Truman, W., Zabala, M.T., and Grant, M. 2006. Type III effectors orchestrate a complex
764	interplay between transcriptional networks to modify basal defence responses
765	during pathogenesis and resistance. Plant J. 46:14-33.
766	Vanitha, S.C., Niranjana, S.R., and Umesha, S. 2009. Role of phenylalanine ammonia lyase
767	and polyphenol oxidase in host resistance to bacterial wilt of tomato. J. Phytopathol.
768	157:552-557.

- Wallis, C.M., and Chen, J. 2012. Grapevine phenolic compounds in xylem sap and tissues are
 significantly altered during infection by *Xylella fastidiosa*. Phytopathology 102:816826.
- Wicker, E., Grassart, L., Coranson-Beaudu, R., Mian, D., Guilbaud, C., Fegan, M., and Prior, P.
 2007. *Ralstonia solanacearum* strains from Martinique (French West Indies)
 exhibiting a new pathogenic potential. Appl. Environ. Microbiol. 73:6790-6801.
- Xu, J., Zheng, H.-j., Liu, L., Pan, Z.-c., Prior, P., Tang, B., Xu, J.-s., Zhang, H., Tian, Q., and Zhang,
 L.-q. 2011. The complete genome sequence of plant pathogen *Ralstonia solanacearum* strain Po82. J. Bacteriol. 193:4261-4262.
- Yao, J., and Allen, C. 2006. Chemotaxis is required for virulence and competitive fitness of
 the bacterial wilt pathogen *Ralstonia solanacearum*. J. Bacteriol. 188:3697-3708.

Strain or Plasmid ^a	Relevant characteristics ^b	Source or Reference	
Strains			
	$F^- mcrA \Delta(mrr-hsdRMS-mcrBC)$		
	φ80 <i>lacZ</i> ΔM15 Δ <i>lacX74 recA1 araD139</i>		
	Δ(ara-leu)7697 galU galK rpsL (Str ^r)		
<i>E. coli</i> TOP10	endA1 nupG	Life Technologies	
R. solanacearum			
GMI1000 (WT)	Wildtype, phylotype I	(Boucher et al., 1985)	
	GMI1000 transformed with pRCG-GWY,		
GMI1000-Gm	Gm ^r	This study	
	GMI1000 transformed with pRCK-GWY,		
GMI1000-Km	Kan ^r	This study	
	GMI1000 with unmarked, precise deletion		
Δfcs	of the feruloyl-CoA synthetase (<i>fcs</i>) ORF	This study	
Δ <i>fcs</i> -Gm	Δfcs transformed with pRCG-GWY, Gm ^r	This study	
Δ <i>fcs</i> -Km	Δfcs transformed with pRCK-GWY, Kan ^r	This study	
	Complemented Δ <i>fcs</i> with Tn7FcsComp		
	integrated into chromosome at the		
Δfcs+fcs	selectively neutral <i>att</i> site, Gm ^r	This study	

781 **Table 1: Strains and plasmids used in this study.**

Plasmids					
	Vector that integrates downstream of				
pRCG-GWY <i>glmS</i> on the GMI1000 chromosome, Gm ^r		(Monteiro et al., 2012)			
	Vector that integrates downstream of				
pRCK-GWY	<i>glmS</i> on the GMI1000 chromosome, Kan ^r	(Monteiro et al., 2012)			
pCR-blunt	Cloning vector	Life Technologies			
pUFR80	pUFR80, Suc ^s (<i>sacB</i>), Kan ^r (Castañeda et al., 2005)				
	Vector that integrates into selectively				
pUC18T-	neutral att site on R. solanacearum				
miniTn7T-Gm	chromosome Gm ^r , Amp ^r (Choi et al., 2005)				
	Helper plasmid for pUC18T-miniTn7T-Gm				
	encoding the site-specific TnsABCD Tn7				
pTNS1	transposase, Amp ^r	(Choi et al., 2005)			
	pUFR80 + <i>fcs</i> markerless deletion				
	construct inserted into <i>sacl/xbal</i> sites in				
pUFR80-fcsKO MCS, Suc ^s (<i>sacB</i>), Kan ^r This study		This study			
	fcs operon (fca-vdh-fcs) with native				
	promoter cloned into <i>hindIII/spel</i> sites in				
pMiniTn7FcsComp	pUC18T-miniTn7T-Gm, Gm ^r , Amp ^r	This study			

- ^bAmp^r, ampicillin resistance; Gm^r, gentamicin resistance; Kan^r, kanamycin resistance; Str^r,
- 784 streptomycin resistance; Suc^s, sucrose sensitivity

785	Fig. 1. Hydroxycinnamic acid (HCA) degradation pathway and genes in <i>R. solanacearum</i>
786	GMI1000. A, The HCA degradation pathway is shown with enzyme names in boldface. Fcs,
787	Fca, and Vdh convert the HCAs ferulate, <i>p</i> -coumarate, and caffeate to the phenolic acids
788	vanillate, <i>p</i> -hydroxybenzoate, and protocatechuate, respectively. VanAB and PobA convert
789	vanillate and <i>p</i> -hydroxybenzoate to protocatechuate, which is further metabolized by the
790	β -ketoadipate enzymes; B , A locus containing genes encoding multiple enzymes in the HCA
791	degradation pathway. White arrows indicate ORFs encoding HCA degradation, and grey
792	arrows indicate neighboring ORFS. RSp0221, RSp0224, and RSp0228 encode
793	transcriptional regulators of the LysR family, MarR family, and Fis family, respectively. The
794	dashed line above the genes indicates the region that was precisely excised to create the
795	feruloyl-CoA synthetase deletion mutant (Δfcs). The solid line below the genes indicates the
796	region used to genetically complement the Δfcs mutation in the Δfcs + fcs strain.
797	
798	Fig. 2. HCA degradation is widely conserved in the <i>R. solanacearum</i> species complex. A,
799	Genetic and functional conservation of HCA degradation. A whole genome comparison
800	phylogenetic tree is shown on the left. Presence of HCA degradation genes and growth of <i>R</i> .
801	solanacearum strains on ferulate (Fer), p-coumarate (Cou), vanillin (Van), vanillate (VA), p-
802	hydroxybenzoate (HBA), and protocatechuate (PCA) are indicated. ^a Growth phenotype
803	differs from genotype prediction; B, <i>fcs</i> encodes a functional feruloyl-CoA synthetase in
804	strain GMI1000. Strains were grown in minimal media supplemented with 0.2 mM
805	succinate, <i>p</i> -coumarate, caffeate, ferulate, or no carbon (-) for 72 hr. Bars represent the
806	mean of 3 biological replicates and error bars indicate standard error of the mean.

.

.

80	7
----	---

808 **Fig. 3.** HCA degradation is required for full virulence of *R. solangcearum*. **A.** Disease 809 progress of WT and Δfcs mutant strains on susceptible tomato plants grown at 28 °C. 810 Twenty-one-day-old unwounded plants (cv. Bonny Best) grown at constant 28 °C were 811 inoculated by pouring a bacterial suspension into the soil of each pot. Symptoms were 812 rated using a 0 to 4 disease index scale. Each point represents the mean disease index of a 813 total of 82 plants per strain, in 6 biological replicates. Bars indicate standard error of the 814 mean. Disease progress of the Δfcs mutant was significantly slower than that of wild-type 815 (P=0.0123, two-way repeated measures ANOVA); **B**, Survival analysis of the above dataset showing the rate of symptom onset after inoculations with WT and the Δfcs mutant; C. 816 817 Disease progress of strains on tomato plants grown in a 24 °C day /19 °C night cycle (1 818 biological replicate with N=16 plants per strain).

819

Fig. 4. Hydroxycinnamic acid degradation does not enhance *R. solanacearum* growth in
plant associated environments. A-C, *ex vivo* bacterial growth in: A, water extract of potting
soil; B, tomato root exudate; and C, tomato xylem sap harvested from stems of uninoculated, healthy plants. Graphs show the mean of 3 replicates.

824

Fig. 5. HCA degradation contributes to root entry and competitive fitness following soil soak inoculation of tomato. A-B, Plants grown at 28 °C were soil-soak inoculated with suspensions of WT or Δfcs bacteria. At 3- and 6-days post inoculation (dpi); A, 300 mg root tissue; or B, 100 mg of midstem tissue were harvested, ground, and dilution plated to

829	determine cell density of <i>R. solanacearum</i> (N=30 plants for root colonization at 3 and 6 dpi;
830	N=20 for stem colonization at 3 dpi and N=30 at 6 dpi); Solid lines represent the median
831	population sizes and the dashed lines represent the limit of detection. WT-gm colonized
832	roots better than Δfcs -gm at 3 days after inoculation (<i>P</i> <0.0094; <i>t</i> -test); C , Competitive
833	fitness of WT vs. Δfcs bacteria following soil-soak inoculation. Tomato plants were co-
834	inoculated with mixtures of reciprocally-marked WT and Δfcs strains. At the first stage of
835	disease (less than 25% leaves wilted), midstem tissue was harvested, ground, and dilution
836	plated. Population size of each strain was normalized by initial inoculum. Median
837	competitive index (CI) of the Δfcs mutant was 0.46 (<i>P</i> <0.0001, Wilcoxon Signed Rank Test;
838	N=13 plants per co-inoculation, 26 total); D , Competition of Δfcs and WT bacteria in tomato
839	stem following direct stem inoculation. Tomato plants were co-inoculated via a cut leaf
840	petiole with 4,000 CFU in a 1:1 suspension of reciprocally-marked WT and Δfcs strains.
841	Midstem tissue was harvested at the first sign of symptoms, ground, and dilution plated.
842	Population size of each strain was normalized by initial inoculum. Median CI of the Δfcs
843	mutant was 0.71 (<i>P</i> =0.225, Wilcoxon Signed Rank Test; N=14 plants per co-inoculation, 28
844	total).

845

Fig. 6. HCA degradation by *R. solanacearum* did not affect total lignin quantity or
distribution in tomato stems. A, Mean gross lignin content in tomato stems at 6 days post
soil-soak inoculation. Whole stems of healthy (mock-inoculated) or infected tomato plants
(*n*=6 per condition) were dried, ground, and analyzed by the acetyl bromide lignin
quantification assay using wood pulp inulin as a standard. Error bars indicate standard

Page 39 of 51

Lowe, Tiffany - MPMI

851 error of the mean. Similar results were obtained at 3 and 9 days after inoculation; B-D,
852 Phloroglucinol HCl-stained cross-sections of stems from representative healthy or
853 symptomatic infected plants. Pink precipitate indicates lignin.

854

Fig. 7. HCA degradation protected *R. solanacearum* from HCA toxicity. Bacterial growth in succinate minimal medium supplemented with increasing concentrations of: **A**, *p*coumarate (*p*-Cou); **B**, caffeate (Caf); or **C**, ferulate (Fer). Culture optical density was measured by a plate reader 48 hr after inoculation with 10^5 CFU/ml of bacteria. Growth of each strain was calculated relative to that of wild-type bacteria growing without HCAs. Error bars indicate standard error of the mean. The WT strain was less inhibited than the Δfcs mutant by *p*-coumarate and caffeate (*t*-test; *P*< 0.005).

862

863 *e*-Xtra Fig. S1. Kanamycin and gentamicin resistance markers did not affect competitive

fitness of strains. **A**, Soil soak competition data of WT and Δfcs bacteria from Fig. 5; **B**,

Petiole competition data of WT and Δfcs bacteria from Fig. 5 Results from the WT-kan: Δfcs -

gm inoculation are shown in filled squares and results from the WT-gm: Δfcs -kan

867 inoculation are shown in open circles.

Strain	Phylotype-	Host isolated	Location	Genome Reference
	sequevar	from		
GMI1000	Ι	Tomato	French	(Boucher et al., 1985;
			Guiana	Salanoubat et al.,
				2002)
FQY4	Ι	Bacterial wilt	China	(Cao et al., 2013)
		nursery		
Y45	I	Tobacco	China	(Li et al., 2011)
Grenada91	IIA-6	Banana	Grenada	Ailloud and Prior,
				unpublished
UW181	IIA-6	Plantain	Venezuela	Ailloud and Prior,
				unpublished
K60	IIA-7	Tomato	USA	(Remenant et al.,
				2012)
B50	IIA-24	Banana	Brazil	Ailloud and Prior,
				unpublished
IBSBF1900	IIA-24	Banana	Brazil	(Wicker et al., 2007)
CFBP2957	IIA-36	Tomato	French West	(Remenant et al.,
			Indies	2010)

868 *e*-Xtra: Table S1: *R. solanacearum* strains used for genomic and functional analyses

UW491	IIB-1	Potato	Colombia	Vinatzer,
				unpublished
UW551	IIB-1	Geranium	Kenya	(Gabriel et al., 2006)
CFBP1416	IIB-3	Plantain	Costa Rica	Ailloud and Prior,
				unpublished
CIP417	IIB-3	Banana	Philippines	Ailloud and Prior,
				unpublished
Molk2	IIB-3	Banana	Philippines	Boucher et al.,
				unpublished
CFBP6783	IIB-4	Heliconia	West Indies	Ailloud and Prior,
				unpublished
IBSBF1503	IIB-4	Cucumber	Brazil	Ailloud and Prior,
				unpublished
Po82	IIB-4	Potato	Mexico	(Xu et al., 2011)
UW163	IIB-4	Plantain	Peru	Ailloud unpublished
UW179	IIB-4	Banana	Colombia	Ailloud and Prior,
				unpublished
CMR15	III	Tomato	Cameroon	(Remenant et al.,
				2010)
BDB R229	IV	Banana	Indonesia	(Remenant et al.,

				2011)
PSI07	IV	Tomato	Indonesia	(Remenant et al.,
				2010)
R. syzygii R24	IV	Clove	Indonesia	(Remenant et al.,
				2011)

869

870 *e*-Xtra Table S2 can be downloaded at:

871 <u>http://www.scientificsocieties.org/MPMIXtras/2014/MPMI-09-14-0292-FI_TableS2.xlsx</u>



Figure 1 175x85mm (300 x 300 DPI)

Genotype Growth Phenotype Α fcs fca vdh vanA vanB pobA pcaG pcaH pcaB pcaC pcaD pcaI pcaJ pcaF Fer Cou Van VA HBA PCA Grenada91 L UW181 Ρ CFBP2957 B50 IIA ٦ IBSBF1900 С K60 Ρ UW491 Ρ UW551 CFBP1416 CIP417 Molk2 IIB CFBP6783 IBSBF1503 UW163 Ρ UW179 С С Po82 Ρ FQY4 С с Y45 GMI1000 CMR15 Ш **BDB R229** PSI07 IV Ρ Ρ *R.syzygii* R24 0.06 Gene homolog present Growth Gene homolog not detected No Growth C Gene is on contig border Not tested P Gene is annotated as possible pseudogene 9 В WT □∆fcs cell density a construction of the second s 6 caffeate none succinate *p*-coumarate ferulate carbon source

Figure 2 175x220mm (300 x 300 DPI)


Figure 3. 81x232mm (300 x 300 DPI)



Figure 4. 169x64mm (300 x 300 DPI)



Figure 5. 176x60mm (300 x 300 DPI)



Figure 6. 175x57mm (300 x 300 DPI)



Figure 7. 175x53mm (300 x 300 DPI)



Supplemental Figure 1. 113x60mm (300 x 300 DPI)

e-Xtra Table S2: Distribution of HCA degradation genes in bacteria with complete genomes

Data table can be downloaded at the following location:

https://drive.google.com/file/d/0Byypeh_Akk8yMlpU0U1rS0xHS00/