Prof. Dr. Ir. Sigit P. HADIWARDOYO, DEA

Jalan dan Model Pengembangan Infrastruktur Transportasi

32 tahun bersama UI untuk Indonesia

Editor: Dr. Andri IRFAN
Setting & Layout: Johan WAHYUDI

© 2018, Kuadran, Bandung
Hak Cipta dilindungi Undang-undang

Jalan dan Model Pengembangan Infrastruktur Transportasi

32 tahun bersama UI untuk Indonesia

Kontributor

Abdellaif BENABDELHAFID
Universite du Havre, France

Andri IRFAN
Direktorat Jenderal Bina Marga, Kementerian PUPR

António Gomes CORREIA
Universidade do Minho, Portugal

Bambang SUSANTONO
Asian Development Bank

Eny YULIAWATI
Badan Litbang, Kementerian Perhubungan

Hamdi
Direktorat Jenderal Bina Marga, Kementerian PUPR

Hedy RAHADIAN
Direktorat Jenderal Bina Marga, Kementerian PUPR

Herry Trisaputra ZUNA
Badan Pengatur Jalan Tol

Hipolito MARTELL-FLORES
Université de Technologie de Compiègne, France

Imam SONNY
Badan Litbang, Kementerian Perhubungan

Jean-Louis BATOZ
Université de Technologie de Compiègne, France

Laurent CARNIS
Institut français des sciences et technologies des transports,
de l'aménagement et des réseaux (Ifsttar)

Lita Sari BARUS
Universitas Esa Unggul

Paulo António Alves PEREIRA
The research Centre for Territory, Environment and Construction, Portugal

R. Jachrizal SUMABRATA
Fakultas Teknik Universitas Indonesia

Susanty HANDAYANI
Badan Pengelola Transportasi Jabodetabek

Yusuf LATIEF
Fakultas Teknik Universitas Indonesia

Daftar Isi

Kata Pengantar v
Sambutan Rektor Universitas Indonesia vii
Daftar Isi.....viii

Bagian I Audit Kelayakan Jalan untuk Mengoptimasi Peran dan Fungsinya

1. Audit Kelayakan Jalan untuk Mengoptimasi Peran dan Fungsinya 1
   Sigit Pranowo HADIWARDOYO

Bagian II Model Pengembangan Infrastruktur Transportasi

2. Model Decision Support System Berbasis Data Mining, Optimasi Manajemen Perkerasan Jalan dengan Muatan Berlebih.....25
   Andri IRFAN, Sigit Pranowo HADIWARDOYO, António Gomes CORREIA

3. Pengembangan Model Kualitas Pelayanan Jalan Tol.....67
   Herry T. ZUNA, Sigit Pranowo HADIWARDOYO, Hedy RAHADIAN

4. Model Sistem Dinamis pada Optimasi Fasilitas Bandara Berdasarkan Prediksi Penumpang 95
   Eny YULIAWATI, Sigit Pranowo HADIWARDOYO, Bambang SUSANTONO, Laurent CARNIS

5. Model Volatilitas Lalu Lintas Dinamis dengan Pendekatan Geometric Brownian Motion untuk Penjaminan Investasi Jalan Tol 131
   Susanty HANDAYANI, Sigit Pranowo HADIWARDOYO, Yusuf LATIEF, R. Jachrizal SUMABRATA

6. The Development of a Freight Distribution Model for Connecting Inter-Island Freight Transport 175
   Imam SONNY, Sigit Pranowo HADIWARDOYO, Bambang SUSANTONO, Abdellaif BENABDELHAFID

7. Contribution to the Intercity Modal Choice considering the Intracity Transport Systems: Application of an Adapted Mixed Multinomial Logit Model for the Jakarta-Bandung Corridor 221
   Lita Sari BARUS, Sigit Pranowo HADIWARDOYO, Jean-Louis BATOZ, Hipolito MARTELL-FLORES

8. Pavement Maintenance Optimization Startegies for the National Road Network in Indonesia Applying Genetic Algorithm 261
Hamdi, Sigit Pranowo HADIWARDOYO, António Gomes CORREIA, Paulo António Alves PEREIRA

Bagian III Implementasi Keilmuan untuk Layanan Prima Transportasi Indonesia

9. Implementasi Pemodelan Data Mining dan Genetic Algorithm untuk Pengembangan Jalan 293
Andri IRFAN, Sigit Pranowo HADIWARDOYO

10. Implementasi Model Peningkatan Pelayanan Transaksi Jalan Tol, Elektronifikasi Jalan Tol 311
Herry T. ZUNA, Sigit Pranowo HADIWARDOYO

11. Langkah Awal Pengembangan Konsep Transportasi Modern di Jabodetabek, Klinik Transit Oriented Development 321
Susanty HANDAYANI, Sigit Pranowo HADIWARDOYO

Profil Penulis x

Kesan Para Sahabat dan Mitra Kerja xii

Model Decision Support System Berbasis Data Mining

Optimasi Manajemen Perkerasan Jalan dengan Muatan Berlebih

2

Andri IRFAN
Direktorat Jenderal Bina Marga, Kementerian PUPR

Sigit Pranowo HADIWARDOYO
Fakultas Teknik Universitas Indonesia

António Gomes CORREIA
Universidade do Minho, Portugal

Abstrak

Jaringan jalan nasional yang terdiri dari struktur jalan tradisional dan jalan modern memerlukan pemeliharaan yang terencana dan sesuai dengan kebutuhan. Terbatasnya pilihan jaringan jalan nasional yang tersedia dan terjadinya penyimpangan pembebanan jalan dengan muatan berlebih mendorong pemerintah untuk lebih tanggap dalam menjalankan manajemen pemeliharaan. Pemerintah sebagai penanggung jawab pemeliharaan jalan sering terkendala oleh terbatasnya anggaran yang tersedia. Disertasi ini bertujuan mengembangkan model *decision support system* (DSS) pemeliharaan perkerasan jalan dengan memanfaatkan ketersediaan pangkalan data pada sistem manajemen perkerasan jalan. Kinerja jalan diukur dengan *nilai international roughness index* (IRI) yang dipengaruhi oleh pavement distress, beban lalu lintas, dan kondisi awal perkerasan. Metode penelitian ini adalah melalui studi eksplorasi, yaitu melakukan kajian pustaka, pengambilan data dan pengamatan visual, dilanjutkan studi eksplanatori, yaitu melalui proses pengembangan model prediksi kinerja jalan, model optimasi, dan model DSS. Model yang dikembangkan berfungsi sebagai alat evaluasi pengambil keputusan bagi berbagai strategi pemeliharaan perkerasan jalan untuk meningkatkan efesiensi dan kinerja jalan. Implementasi model terhadap beberapa kasus hipotetikal dengan menggunakan algoritma dan script hasil pengembangan penelitian ini, memperlihatkan bahwa pendekatan *data mining* (DM) dengan algoritma *support vector machine* (SVM) dan *artificial neural network* (ANN), serta pendekatan *multi obejective optimization* (MOO) dengan *genetic algorithm* (GA) memberikan alternatif strategi pemeliharaan perkerasan jalan dengan muatan berlebih. Selain itu, konsep DSS yang dikembangkan dengan pendekatan *geographical information system* (GIS) mampu memberikan pendekatan yang lebih sederhana bagi pengambil keputusan di setiap tingkat untuk menjalankan manajemen pemeliharaan jalan secara komprehensif.

2.1 Pendahuluan

Jaringan jalan direncanakan, dibangun dan dipelihara untuk memfasilitasi transportasi dengan aman, nyaman, dan efisien. Untuk mewujudkan tujuan tersebut,

dalam beberapa dekade terakhir sistem manajemen perkerasan jalan terus dikembangkan. Sebagai contoh, Amerika Serikat melakukan pengembangan sistem manajemen perkerasan jalan melalui American Association of State Highway Officials (AASHO) pada akhir tahun 1950-an (Akofio-Sowah & Kennedy, 2014). Pada rentang waktu tersebut bukan hanya negara maju saja yang melakukan pengembangan sistem manajemen perkerasan jalan. Melalui bantuan World Bank, sistem manajemen perkerasan jalan di negara berkembang pun terus diperbaiki dengan mengembangkan Highway Development and Management (HDM) sejak tahun 1966. Dalam perkembangannya, HDM dikalibrasi sesuai dengan kondisi dan standar yang berlaku di masing-masing negara pengguna. Sejak tahun 1994 hingga saat ini HDM-4 dikembangkan untuk menjawab tuntutan global di sektor jalan yang semakin kompleks, yang mencakup keselamatan jalan, lingkungan, dan energi, selain aspek manajemen (Martinaz Diaz & Perez, 2015).

Seiring dengan waktu, tujuan sistem manajemen perkerasan jalan terus berkembang. Pada tahap awal, pemerintah sebagai penyelenggara jalan terus melakukan penambahan kapasitas jalan secara fungsional. Namun saat ini selain tetap menambah kapasitas jalan, penyelenggara jalan pun harus memenuhi harapan yang lebih tinggi dari pengguna jalan berupa kenyamanan, kemudahan, dan keamanan. Sehubungan dengan hal tersebut penyelenggara jalan dan seluruh stake holder harus terus mengembangkan diri untuk mempertahankan, memperluas dan meningkatkan kinerja sistem jaringan jalan yang telah ada. Salah satu langkah untuk mencapai tujuan ini diperlukan sistem manajemen yang lebih baik agar semua sumberdaya yang dimiliki dapat dioptimalkan. Melalui pendekatan terkini yang dibantu oleh matematika modern dan teknologi komputer, alokasi anggaran sebagai salah satu sumber daya untuk peningkatan sistem manajemen perkerasan jalan dapat diimplementasikan secara lebih efesien (Santos & Ferreira, 2012).

Sistem manajemen perkerasan jalan dilakukan secara berkesinambungan, mulai dari perancangan, perencanaan, pembangunan, operasional, pemeliharaan, sampai dengan pengendalian. Seluruh tahapan dalam siklus sistem manajemen perkerasan jalan memiliki peranan yang sama pentingya. Tahapan sistem manajemen perkerasan jalan memiliki pengaruh yang signifikan dalam menjaga kinerja jalan apabila dilakukan secara berkesinambungan dalam rentang waktu yang panjang (Ding, et al., 2013). Hal tersebut dipengaruhi oleh sifat dan karakter struktur perkerasan jalan yang dapat dipolakan dengan berbagai pendekatan data dan catatan historis lainnya. Umur layan jalan antara 20 untuk perkerasan lentur dan 40 tahun untuk perkerasan kaku. Setelah itu dapat dilakukan rekonstruksi yang akan menambah umur rencana kembali. Sehingga hakikatnya badan jalan merupakan hasil pembangunan yang punya sifat pengulangan konstruksi pada satu tempat. Hal tersebut mengharuskan pengelola jalan tol memiliki catatan yang baik tentang sejarah setiap ruas jalan.

Kinerja jalan dapat berkurang sebanding dengan bertambahnya umur perkerasan serta beban lalu lintas (Yuhong Wang, et al., 2014). Pada umumnya umur perkerasan jalan ditetapkan berdasarkan *cumulative equivalent standard axle* (CESA) yang diperkirakan melintasi perkerasan jalan tersebut, diperhitungkan dari mulai perkerasan jalan tersebut dibangun, dioperasikan, sampai dengan perkerasan jalan tersebut

dikategorikan rusak (berakhir umur rencana). Proses penurunan umur jalan tidak bersifat linier. Penurunan kinerja jalan secara keseluruhan mengikuti fungsi pertambahan volume dan beban lalu lintas, perubahan kondisi lingkungan, serta kondisi lainnya (Hass, 2003) seperti dapat dilihat pada gambar 2.1(a).

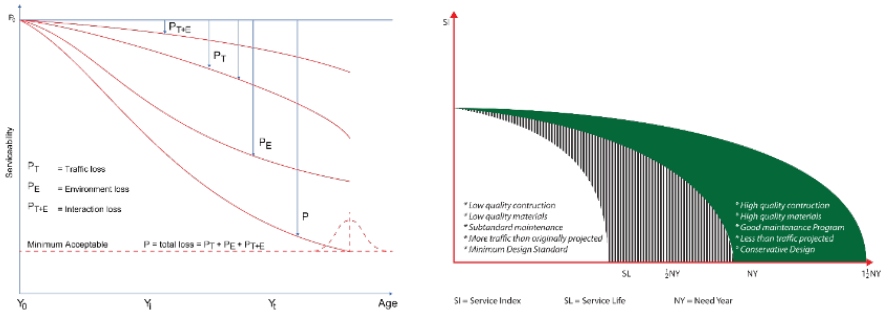

a. *(Hass, 2003)* b. *Watson (1989) & Cheser, at.al. (1987)*

Gambar 2.1. Penurunan kinerja jalan

Pada dasarnya lapis perkerasan jalan dapat mengalami penurunan fungsi struktural sesuai dengan bertambahnya umur. Namun demikian, fungsi perkerasan pada jaringan jalan sering mengalami kerusakan struktural sebelum umur rencana tercapai, akibat berbagai kondisi dalam masa operasi. Salah satu fenomena yang umum terjadi di negara berkembang adalah muatan berlebih (Ede, 2014). Kondisi tersebut terjadi terus menerus tanpa dapat dicegah. Alasan keterbatasan moda transportasi serta tujuan meminimalkan biaya angkut menyebabkan kerusakan jalan lebih cepat terjadi. Muatan berlebih di atas batas kewajaran serta beban berulang mengakibatkan kerusakan yang besar dan merubah umur layan seperti dapat dilihat pada gambar 2.1(b). Dalam penelitiannya, Sianipar & Dowaki (2014) menegaskan bahwa muatan berlebih merupakan faktor terbesar yang mendorong kerusakan perkerasan jalan sekaligus kerusakan lingkungan. Pembiaran muatan berlebih terus menerus, secara langsung dapat menimbulkan melonjaknya biaya pemeliharaan (Pais, et al., 2013). Biaya pemeliharaan yang diperlukan akibat muatan berlebih bukan hanya untuk pengembalian fungsi lapis perkerasan atas saja, namun juga harus mempertimbangkan lapisan pondasi. Hal tersebut karena kerusakan yang diakibatkan oleh muatan berlebih, kerusakannya mampu mencapai lapis pondasi dan pondasi bawah (Hadiwardoyo, et al., 2012).

Sesaat sebelum kerusakan mencapai lapis bawah, indikasi kerusakan diawali oleh kerusakan permukaan. Tingkat kerataan dan kekesatan permukaan berubah sesuai dengan perubahan kinerja jalan. Kerataan permukaan jalan (roughness) merupakan indikator penting, karena secara langsung mempengaruhi pengemudi dan kendaraan. Angka atau indeks kerataan terkait dengan amplitudo dan frekuensi distorsi perkerasan, karakteristik suspensi kendaraan, dan kecepatan kendaraan. Kondisi kerataan jalan yang tidak baik dapat menurunkan kecepatan, menimbulkan potensi kerusakan kendaraan, meningkatkan biaya operasional, dan meningkatkan emisi gas buang (Hass, 2003). Sampai saat ini international roughness index (IRI) masih merupakan salah satu alat ukur kinerja jalan yang digunakan dalam sistem manajemen perkerasan jalan secara luas.

IRI mulai dikembangkan pada tahun 1986 oleh World Bank yang merupakan pengembangan dari konsep NCHRP. Pertama kali diperkenalkan dalam international road roughness experiment (IRRE) yang dilaksanakan di Brasil (Sayers & Karamihas, 1995). IRI diukur dengan mengumpulkan data keluaran dari kendaraan uji atau langsung dibagi dengan panjang profil untuk menghasilkan ringkasan indeks kerataan. IRI telah diterima secara internasional sebagai indikator kinerja jalan yang dapat terus dikalibarasi untuk wilayah dan kondisi berbeda.

Penurunan kinerja jalan tidak berlangsung dalam waktu seketika, namun bertahap mengikuti fungsi waktu dan bersifat time series. Kecepatan dan bentuk perubahan kinerja memiliki pola dan kecenderungan tertentu. Pengumpulan data dalam jumlah besar, mutlak diperlukan untuk dapat menghasilkan pola yang baik dan berkesinambungan (Varela-González, et al., 2014). Pendekatan teknik baru dan pemanfaatan teknologi terkini perlu dilakukan agar sekumpulan data yang telah dikumpulkan dapat dimanfaatkan secara terstruktur dan terukur guna mendukung sistem manajemen perkerasan jalan yang lebih baik melalui interpretasi dan prediksi data yang akurat.

Interpretasi dan prediksi data merupakan salah satu hal penting dalam sistem manajemen perkerasan jalan. Kelompok data yang sangat besar hanya menjadi informasi tanpa makna apabila tidak dilakukan interpretasi dan prediksi secara tepat dan akurat. Sehubungan dengan hal tersebut, diperlukan sebuah model yang dapat memberikan pendekatan proses interpretasi yang baik. Data mining (DM) adalah salah satu pendekatan yang banyak digunakan untuk interpretasi data dalam berbagai disiplin ilmu. Melalui pendekatan *artificial intelligence* (AI), DM memiliki potensi yang sangat besar untuk membantu melakukan interpretasi dan prediksi (Cortez, 2010). Pemanfaatan AI dalam kelompok keilmuan teknik sipil telah dilakukan oleh Terzi (2006) dengan menyusun model prediksi pavement serviceability index (PSI) dan surface distress index (SDI). Selanjutnya Zhou (2010) melakukan pengembangan model geographic information system (GIS) pemeliharaan jalan; pengembangan model prediksi jet grouting (Tinoco, et al., 2014); serta model klasifikasi fungsional jalan (D'Andrea, et al., 2014). Dalam penelusuran pustaka yang dilakukan, sampai saat ini pendekatan AI dan teknik DM belum dikembangkan untuk pemodelan prediksi IRI dalam peningkatan kemampuan sistem manajemen perkerasan jalan.

Berbagai atribut dalam sistem manajemen perkerasan jalan harus mendapatkan perhatian yang seimbang. Seluruh permasalahan dan tujuan sebaiknya ditangani dan diselesaikan dengan menyeluruh secara berkesinambungan. Beberapa tujuan yang secara bersamaan harus dicapai, memerlukan pendekatan *multi-objective optimization* (MOO). Secara umum, tidak ada solusi optimasi yang bersifat tunggal yang secara bersamaan dapat menghasilkan nilai minimum atau maksimum untuk semua objective (Saha & Ksaibati, 2015). Begitu juga dalam sistem manajemen perkerasan jalan, penyelenggara jalan perlu mempertahankan kinerja jalan setinggi mungkin dengan tetap menjaga biaya yang digunakan serendah mungkin dalam waktu bersamaan. Kedua objective yang bertentangan satu sama lain, karena untuk menjaga tingkat kinerja jalan yang tinggi diperlukan penambahan biaya, dan sebaliknya. Beberapa objective, baik yang

muncul terpisah maupun secara bersama-sama tetap harus menjadi perhatian bagi pemegang keputusan.

Seiring waktu metode optimasi semakin lengkap dan memiliki pilihan beragam yang dapat disesuaikan dengan kondisi dan karakteristik yang ada. Pada kurun waktu yang cukup lama pengembangan model MOO dengan GA berhasil diimplementasikan dalam berbagai bidang (Elhadidy, et al., 2015). Pendekatan GA merupakan pendekatan yang cukup praktis dan telah banyak digunakan secara luas dalam berbagai bidang keilmuan (Morcous & Lounis, 2005). Melalui pendekatan GA diharapkan atribut yang tidak diperkirakan di masa yang akan datang seperti ketidakpastian pertumbuhan lalu lintas dan muatan berlebih pada jaringan jalan, mulai dapat dipetakan dari awal sebagai bahan pertimbangan pemegang kebijakan.

Terakhir, sistem manajemen perkerasan jalan yang baik adalah sistem yang mampu memberikan sebuah tools kepada para pengguna dan pengambil keputusan, sehingga mampu memahami dan menggunakan sistem dengan sederhana. Coutinho-Rodrigues et al. (2011) menuliskan bahwa semakin mudah sebuah sistem digunakan maka semakin optimal kemampuan sistem tersebut dapat digunakan dalam mendukung kinerja organisasi. Sehubungan dengan hal tersebut diperlukan pengembangan decision support system (DSS) yang sederhana dan mudah dipahami untuk menyempurnakan sistem manajemen perkerasan jalan yang ada. Berdasarkan uraian beberapa konsep model yang ada, model optimasi pemeliharaan jalan dengan pertimbangan MOO diperlukan untuk menjelaskan bagaimana sesungguhnya optimasi dan penentuan prioritas dilaksanakan sejak awal pemeliharaan dengan pemanfaatan DM. Model optimasi ini diharapkan menjadi alternatif untuk melengkapi beberapa konsep model lain yang sudah ada. Hasil pemodelan optimasi tersebut harus mampu memberikan solusi perbaikan untuk penyempurnaan model optimasi, sekaligus sebagai bahan awal dalam penyusunan konsep DSS pemeliharaan jalan yang lebih komprehensif.

2.2 Tinjauan Pustaka

2.2.1 Artificial Intellegence

Metode *soft computing* dilakukan dengan meniru proses yang ditemukan di alam, seperti otak dan seleksi alam (Tinoco, et al., 2014). Teknik *soft computing* memungkinkan pengolahan data dengan ketidakpastian, tidak tepat, dan ambigu. Pada pertengahan awal 1960-an cabang baru ilmu komputer mulai menarik perhatian sebagain besar ilmuwan. Cabang baru ini, disebut sebagai AI, dapat didefinisikan sebagai studi tentang bagaimana menjadikan komputer mampu mendorong kualitas pekerjaan orang menjadi lebih baik. Untuk mencapai tujuan tersebut, komputer dikembangkan dengan cara meniru perilaku manusia. Pada tahun 1970-an AI lebih terfokus pada pengembangan *expert system* yang disusun untuk mendukung pengambilan keputusan melalui pendapat para ahli yang dikomputasi. Kemudian, di tahun 1990-an perkembangan AI terjadi pergeseran, yaitu mempelajari berbagai masalah langsung dari data (Liao, et al., 2012). Sampai saat ini AI terus berkembang dan meliputi beberapa

metode dan solusi pada lintas ilmu. Pada gambar 2.2 dapat dilihat perkembangan AI dalam berbagai area keilmuan. Perkembangan AI mulai tahun 1970 semakin berkembang, ditandai dengan mencairnya pendekatan *numeric* dan *symbolic* yang saling melengkapi.

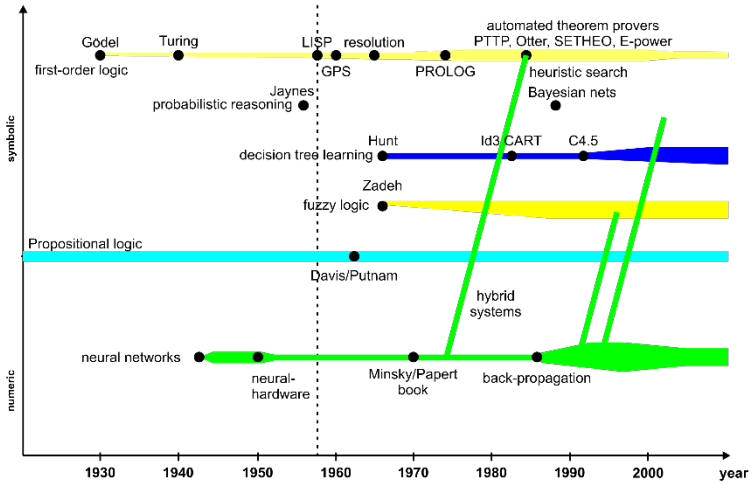

Gambar 2.2. Perkembangan *Artificial Intelligence* (Ertel, 2009)

Perkembangan industri teknologi informasi yang sangat cepat, keilmuan dalam pengumpulan data pun tumbuh pesat. Pangkalan data dalam ukuran besar tidak menjadi masalah apabila dapat memanfaatkan teknologi komputer dengan berbagai aplikasi utama dan pendukungnya. Semua data yang telah dikumpulkan dan disimpan dalam pangkalan data yang baik dapat menjadi pengetahuan yang sangat berharga yang dapat digunakan untuk mendukung pengambilan keputusan dan optimasi sebuah tindakan (Liu, et al., 2010). Statistik klasik memiliki keterbatasan untuk melakukan analisis data dengan jumlah besar atau ketika fungsi hubungan yang kompleks antara variabel data. Untuk mengatasi keterbatasan tersebut, perlu dikembangkan alat bantu analisis data berbasis komputer dengan kemampuan yang lebih besar dan bersifat otomatis (Rahman, et al., 2014). Perkembangan pendekatan semi-otomatis dalam berbagai bidang ilmu, beberapa dekade terakhir telah terjadi peningkatan dan lintas disiplin ilmu, seperti AI, statistik dan sistem informasi. Bidang ini secara formal didefinisikan sebagai *knowledge discovery from database* (KDD). Wang (2012) menyebutkan dalam perkembangannya KDD semakin dikenal dengan istilah DM. Selanjutnya dalam disertasi ini, terminologi DM sering digunakan sebagai sinonim dari KDD.

2.2.2 Data Mining

Pemahaman dan pendalaman bidang keilmuan memberikan pengaruh penting dalam keberhasilan merancang algoritma DM. Pangkalan data hanya merupakan sekumpulan data tanpa arti apabila tidak dilakukan pendekatan dengan algoritma yang tepat (Fu, 2011). Selanjutnya Fu juga menyampaikan bahwa hasil review yang dilakukan

dalam beberapa tahun terakhir, kemampuan DM semakin berkembang dalam domain tertentu dan sangat tergantung dengan jumlah para peneliti yang secara berkesinambungan mengembangkan algoritma tertentu. Dalam kasus sederhana, keilmuan dapat membantu mengidentifikasi fitur yang tepat untuk memodelkan data yang mendasari penyusunan pangkalan data Keilmuan dan pengetahuan juga dapat membantu merancang tujuan bisnis yang dapat dicapai dengan menggunakan analisis pangkalan data secara mendalam.

Salah satu langkah dalam menyusun model prediksi kinerja jalan dalam sistem manajemen perkerasan adalah mengolah data kondisi jalan dalam sebuah proses KDD untuk membentuk data mining kemiskinan. DM adalah kombinasi secara logis antara pengetahuan data, dan analisa statistik yang dikembangkan dalam pengetahuan bisnis atau suatu proses yang menggunakan teknik statistik, matematika, kecerdasan buatan, tiruan dan *machine-learning* untuk mengekstraksi dan mengidentifikasi informasi yang bermanfaat bagi pengetahuan yang terkait dari berbagai database besar. Dalam tahapan KDD, algortima DM dilengkapi dengan dataset yang digunakan selama *learing-phase*, untuk dikembangkan menjadi model *data-driven*. Model tersebut dapat digambarkan sebagai hubungan antara *input* dan *output*, yang dapat memberikan informasi yang bermanfaat.

2.2.3 Optimasi Pemeliharaan Perkerasan Jalan

Pendekatan optimasi dalam sistem manajemen perkerasan jalan diperlukan untuk mengoptimalkan sumber daya yang terbatas untuk memenuhi kebutuhan pemeliharaan perkerasan jalan yang terus berkembang. Bakoo & Horvath (2011) melakukan penelitian dan menghasilkan keputusan untuk mengembangkan model formulasi program linier, melalui *markov transition probability matrix approach*, dan mereka memperkenalkan model prediksi kinerja jalan melalui bantuan program komputer mikro. Model tersebut dapat menghasilkan perhitungan kebutuhan dana dan alokasi anggaran yang optimal untuk seluruh jaringan, tetapi penelitian ini tidak mengangkat perbedaan kelas, dan juga mengasumsikan kerusakan menjadi linear. Studi di atas kemudian diikuti oleh (Moazami, et al., 2011) yang memodelkan pendekatan sistem dengan prioritas menggunakan *fuzzy logic*. Hasil pemodelan yang dihasilkan melalui modifikasi mesin iterasi masih perlu penyempurnaan agar jumlah variabel *input* yang dibentuk oleh pendekatan *fuzzy* lebih akurat. Model optimasi tidak hanya digunakan dalam pemeliharaan perkerasan, tapi digunakan juga untuk mendapatkan hasil perencanaan yang optimal, salah satu model yang ada saat ini adalah integrasi algoritma genetika dengan sistem informasi geografis jalan untuk mendapatkan penyelarasan yang optimal (Kang, et al., 2012) dan (Beg & Banerjee, 2015).

Dalam pemahaman sederhana, optimasi melibatkan berbagai sumber daya untuk memaksimalkan atau meminimalkan fungsi *objective* dari beberapa biner, variabel keputusan integer dengan mempertimbangkan ketidaksetaraan kendala. Sebuah kendala dengan fungsi *single-objective* jarang terjadi dalam masalah manajemen perkerasan jalan. Dalam sistem manajemen perkerasan jalan justru berbagai *objective*

dan kendala harus diselesaikan dalam waktu bersamaan. *Objective* yang diharapkan dapat dicapai lebih dari satu dan bertentangan, sehingga perlu dilakukan optimasi secara simultan atau dengan cara minimalisasi beberapa *objective function*. Pendekatan *single objective optimization*, merupakan gagasan optimasi dengan tujuan meminimalkan atau memaksimalkan satu nilai *objective* tertentu (Di Mino, et al., 2013). Sedangkan pendekatan MOO terdiri dari dua atau lebih *objective* yang perlu dioptimasikan

Sejak awal tahun 1980-an, telah banyak pendekatan optimasi yang digunakan dalam sistem manajemen perkerasan jalan, misalnya *integer goal programming* (Cook, 1984), *linear goal programming* (Benjamin, 1985), *linear programming* (Karan & Haas, 1976) dan (Lytton, 1985), *linear integer programming* (Mahoney, et al., 1978), (Garcia-Diaz & Liebman, 1980), (Fwa & Shinha, 1988b), (Li & Huot, 1998), (Ferreira, et al., 2002) dan (Wang, et al., 2003), *dynamic programming* (Feighan, et al., 1987) dan (Tack & Chou, 2002), serta GA seperti (Chan, et al., 1994), (Fwa, et al., 1994a), (Fwa, et al., 1996) (Fwa, et al., 2000), (Pilson, et al., 1999) (Chikezie, et al., 2011), (Gao, et al., 2012), (Marzouk, et al., 2012) dan (Elhadidy, et al., 2015). Cukup banyak pendekatan untuk memaksimalkan kinerja jalan melalui sistem manajemen perkerasan jalan, pemeliharaan dan rehabilitasi, serta meminimalkan biaya pemeliharaan (Haas, et al., 1994), (Shahin, 1994), (Harper & Majidzadeh, 1991), (Hill, et al., 1991), (Hill, et al., 1991), (Abaza & Ashur, 1999), (Abaza, et al., 2004), (Abaza, 2006), dan (Abaza & Murad, 2007). Salah satu permasalahan besar dalam optimasi sumber daya sistem manajemen perkerasan jalan adalah optimasi jumlah variabel keputusan yang harus ditentukan cukup banyak (Harper & Majidzadeh, 1991), (Pilson, et al., 1999), (Abaza, et al., 2001), (Ferreira, et al., 2002), dan (Elhadidy, et al., 2015).

2.2.4 Decision Support System

Model DSS telah banyak digunakan dalam berbagai disiplin ilmu termasuk industri infrastruktur (Gluch & Baumann, 2004) dan (Rahman & Vanier, 2004). Kebutuhan alat bantu pengambilan keputusan di industri infrastruktur semakin meningkat, karena tingginya tingkat ketidakpastian yang melekat. Hal ini perlu juga diterapkan pada sistem manajemen perkerasan jalan. Berbagai kondisi dalam sistem manajemen perkerasan jalan tidak mungkin diketahui secara pasti, sehingga alat pendukung keputusan dapat membantu dalam meningkatkan keakuratan proses pengambilan keputusan selama proses pemeliharaan jalan (Zhang & Murphy, 2013).

Setiap kegiatan tersebut membutuhkan keputusan yang tidak jarang mendekati ambigu serta meragukan. Selain itu, karena adanya ketidakpastian masalah serta sisi subyektif dari para pengambil keputusan, unsur sosial politik, serta tidak ada nilai obyektif yang sepenuhnya dalam menemukan solusi terbaik (Gendreau & and Duclos, 1989). Sehingga dalam melaksanakan proses manajemen secara efektif, beberapa jenis sistem pendukung keputusan penting dimiliki dan dapat diimplementasikan (Fedra & Reitsma, 1990), (Coutinho-Rodrigues, et al., 2011), (Rouhani, et al., 2012), dan (Lemis-Petropoulos, et al., 2012). Dengan pendukung keputusan yang baik, maka proses manajemen lanjutan bisa mendapatkan dukungan penuh pada setiap tahapan proses.

2.2.5 Literature Map

Berbagai penelitian dalam sistem manajemen perkerasan jalan menyatakan bahwa prediksi kinerja jalan adalah langkah awal yang menentukan keberhasilan dalam optimasi pelaksanaan pemeliharaan jalan. Penggunaan AI dalam melakukan analisa terhadap data yang sangat besar dan tidak beraturan merupakan pendekatan yang terarah. Pendekatan MOO dengan GA yang terintegrasi dengan DM untuk membangun DSS diyakini sebagai *state of the art* dalam penelitian ini. Hasil kajian pustaka yang telah dilakukan dapat disederhanakan ke dalam sebuah skema yang terdiri dari dua kelompok utama dan beberapa kelompok pendukungnya, seperti dapat dilihat pada gambar berikut.

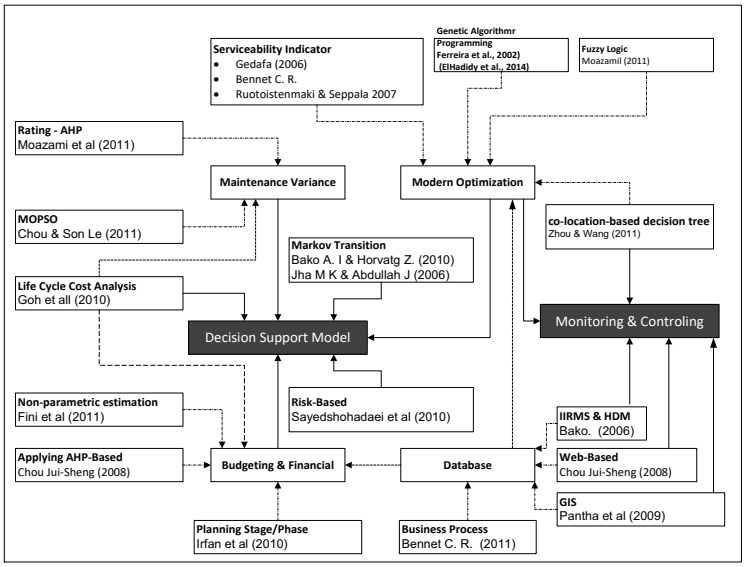

Gambar 2.3. *Literature Map*

2.3 Metodologi Penelitian

Model DM merupakan model yang dipilih untuk menjawab pertanyaan penelitian secara umum. Tahap pertama penggunaan DM untuk prediksi kinerja jalan guna menjawab pertanyaan pertama, selanjutnya DM diintegrasikan dengan MOO untuk menjawab pertanyaan kedua, dan DM beserta MOO yang disusun dalam pendekatan GIS sebagai sebuah konsep untuk menjawab pertanyaan ketiga. Pada gambar 2.4 diuraikan secara ringkas kerangka metodologi penyusunan model.

Algoritma yang digunakan dalam alur penelitian ini menggunakan *tools* bahasa komputer untuk mempermudah penulisan formula, serta mencatatkan proses pengembangan model tersebut. Berikut ringkasan *tools* yang digunakan dalam penelitian, yaitu:

1. *R tools*. R adalah unit *software* yang terintegrasi dengan beberapa fasilitas untuk melakukan rekayasa komputasi dengan kemampuan perhitungan dan kinerja grafis

yang handal. R adalah kelompok dari bahasa pemrograman S, dikembangkan oleh AT & T Bell Laboratories (sekarang Lucent Technologies) pada akhir 1970an. R adalah versi gratis dari bahasa S software yang mirip dengan S-PLUS, yang secara luas digunakan oleh para peneliti dan akademisi dalam kegiatan ilmiah. Lingkungan R adalah *open source* dan merupakan bahasa pemograman matrik tingkat tinggi, secara luas digunakan untuk analisis data dan statistik. R memiliki kemampuan melakukan operasi statistik (linier dan pemodelan nonlinier, uji statistik klasik, klasifikasi, *clustering*, dan lain sebagainya), grafis, *object oriented design*. Aplikasi ini juga dibuat mudah *extensible* dengan penciptaan aplikasi baru yang dapat diterapkan melalui pengembangan package. Komunitas R sangat aktif dan *package* baru terus dikembangkan. Salah satu *package* tersebut adalah *rminer* (Cortez, 2010) yang tersedia secara online dan dapat diakses secara gratis di beberapa sumber, salah satunya di http://www3.dsi.uminho.pt/pcortez/rminer.html.

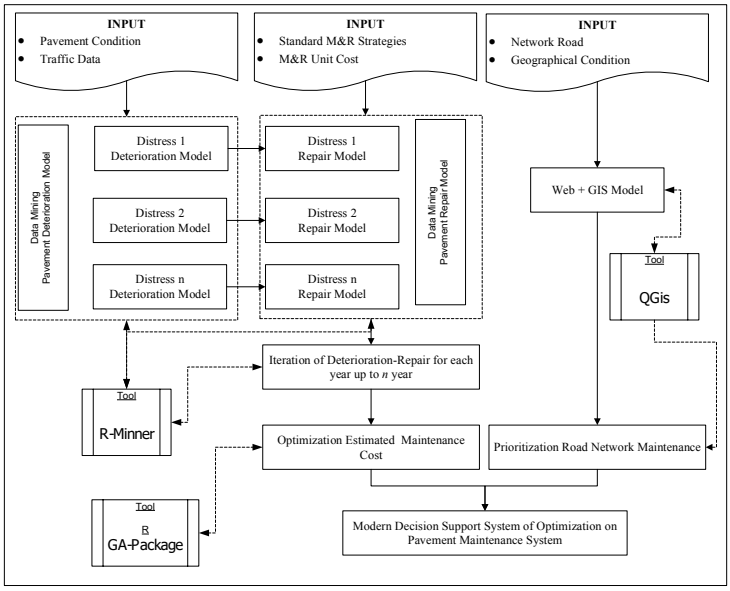

Gambar 2.4. Kerangka metodologi DSS manajemen pemeliharaan jalan

2. *R package GA*. Paket GA dari R untuk optimasi menggunakan algoritma genetika. Paket ini menyediakan *objective flexible* dengan menerapkan algoritma genetika sebagai pencarian solusi yang bersifat kontinyu dan diskrit. Pengguna dapat dengan mudah menentukan fungsi tujuan, tergantung pada masalah yang dihadapi. Beberapa operator genetik yang tersedia dapat dikombinasikan untuk mengeksplorasi pengaturan terbaik. Selanjutnya, pengguna dapat menentukan operator genetik baru dan dengan mudah mengevaluasi kinerja model. GA dapat dijalankan secara berurutan.
3. QGis merupakan perangkat pelengkap untuk menyusun dan mengitegrasikan DSS yang bersifat FOSS (*free and open source Software*). *Source code* tersedia dalam bentuk *general public license* (GPL). Dalam penelitian ini digunakan *QGis Lisboa version.*

2.4 Pengembangan Model Data Mining

Model prediksi kinerja jalan yang dikembangkan dalam penelitian ini terdiri dari tiga algoritma yaitu ANN, SVM dan MR. ANN dan SVM diuraikan dan dikaji secara utuh, sedangkan MR sebagai pembanding dalam proses validasi model. Seluruh algoritma menggunakan agoritma yang dikembangkan oleh *R-core team* dan *rminer library*.

2.4.1 Arsitektur Model

Untuk melakukan pemodelan dengan algoritma DM diperlukan data historis dengan rentang waktu yang cukup panjang (Rifai, et al., 2015). Data tersebut dijadikan *learning data, test data,* dan *validation data*. Data terkumpul ditabulasi dan disusun berdasarkan tahapan prosedur DM. Kumpulan data dan uraian serta sumber data yang digunakan dalam penelitian ini dapat dilihat pada tabel 2.1. Sumber data sendiri menggunakan basis data eksisting yang ada di Ditjen Bina Marga.

Tabel 2.1. Data dan Sumber

No	Data	Sumber Data		Prediksi Kinerja	
		IIRMS	Hawkeye	HDM-4	DM
1	ID_Road	√		ID	ID
2	Age	√		Age	A
3	IRI_0	√		IRI_0	IRI_0
4	IRI	√			IRI
5	Alligator *Crack*ing (m^2)	√	√		AC
6	Longitudinal *Crack*ing (mm)	√	√	ACA (%)	LC
7	Block *Crack*ing (m^2)	√	√		BC
8	Transversal *Crack*ing (mm)	√	√	ACT (%)	TC
9	Potholes number (no/km)	√	√	Potholes	PN
10	Rutting (m^2)	√	√		RU
11	Depression/ Deformation (m^2)	√	√		DS
12	Structural Patching (m^2)	√	√		SP
13	Seal Patching (m^2)	√			SE
14	ESAL (million)	√	√		ESAL
15	AADT (vehicle/day)	√		AADT	
16	Coordinate (x;y;z)		√		(GIS)

Setelah data ditabulasi pada pangkalan data baru, selanjutnya dilakukan metode *learning* dengan memasukkan target *output* dalam data sebagai bagian dari proses *learning*. Ada beberapa metode *learning* yang telah dikembangkan oleh para peneliti, diantaranya yang sering diaplikasikan adalah *single perseptron*, *multi perseptron* dan tentunya BP. Metode BP sampai saat ini masih sangat banyak yang menggunakan, begitu juga yang telah dimodifikasi sehingga menjadi lebih efektif kinerjanya. Jaringan *multi*

layer perseptron terdiri dari beberapa unit neuron seperti gambar 1.5, yang terhubung dan mempunyai beberapa masukan serta sebuah atau beberapa keluaran.

Variabel *input* dari model ANN untuk model prediksi IRI adalah IRI_0, Age, ESAL, PN, SE, SP, AC, IC, BC, TC, RU, dan DP. Dalam penelitian ini, set data yang diambil untuk pemodelan prediksi IRI mencakup 10.680 sampel dari 712 ruas jalan nasional.

2.4.2 Karakteristik Data

Langkah pertama dalam analisis data adalah menggambarkan data dengan parameter sederhana menggunakan metode statistik. Analisa data awal menggunakan aplikasi R dengan *package-mcmdr* untuk menguraikan parameter statistik utama, yaitu maksimum, minimum, rata-rata dan deviasi standar data. Untuk analisis data multidimensi, hal penting untuk memastikan jika dua variabel x_i dan x_j secara statistik saling ketergantungan. Sebagai contoh, kovarians (didefinisikan dalam Persamaan 2.1) memberikan informasi tentang masalah ini.

$$\sigma_{ij} = \frac{1}{N-1}\sum_{p=1}^{N}\left(x_i^p - x_i\right)\left(x_j^p - x_j\right) \quad \text{.....} 2.1$$

Namun, kovarians juga tergantung pada nilai absolut dari variabel, yang membuat perbandingan nilai-nilai yang sulit. Untuk membandingkan tingkat ketergantungan dalam kasus beberapa variabel, sebaiknya dihitung menggunakan koefisien korelasi (Ertel, 2009):

$$K_{ij} = \frac{\sigma_{ij}}{s_i - s_j} \quad \text{.....} 2.2$$

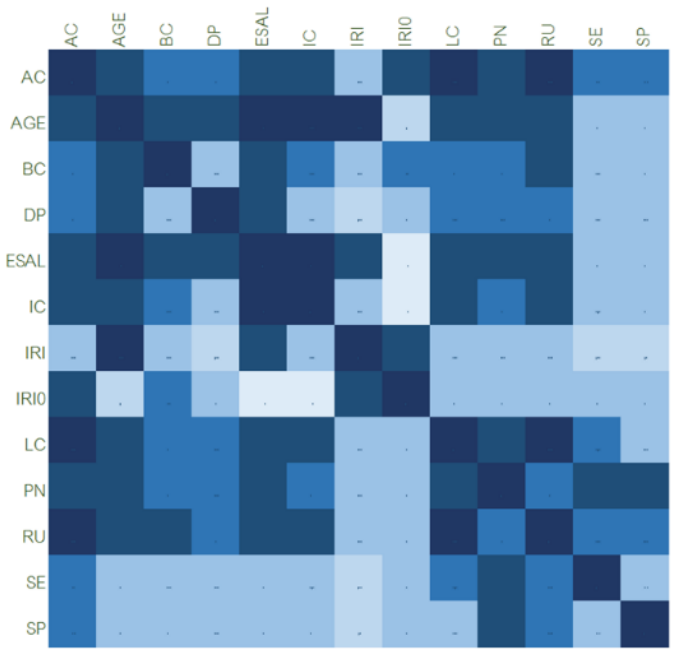

Gambar 2.5. *Correlation Matrix*

Untuk dua nilai x_i dan x_j, adalah koefesien kovarians yang dinormalisasi. Matriks K dari semua koefisien korelasi mengandung nilai antara {1 dan 1, simetris, dan semua elemen diagonalnya memiliki nilai 1}. Untuk memudahkan interpretasi matriks K, dapat direpresentasikan dalam *density plot*. Oleh karena itu, bukan sekedar nilai-nilai numerik, elemen matriks diisi dengan *blue values*. Pada gambar 2.5 ditunjukan matriks korelasi untuk semua 13 atribut dan variabel target dalam penelitian ini. Dalam gambar ini nilai absolut dianggap tetap, rata-rata penggambaran dengan warna putih $k_{ij} \approx 0$ (*uncorrelated*) dan biru menunjukan $k_{ij} \approx 1$ (strongly correlated).

2.4.3 Aktivasi ANN dan SVM

Selanjutnya, model ini dikembangkan dengan mengaktifkan seluruh jaringan dalam ANN. Mengaktifkan jaringan saraf tiruan berarti mengaktifkan setiap neuron yang dipakai pada jaringan tersebut. Banyak fungsi yang dapat dipakai sebagai pengaktif, seperti fungsi-fungsi goniometri dan hiperboliknya, fungsi unit step, impulse, sigmoid, dan lain, tetapi yang lazim digunakan adalah fungsi sigmoid, karena dianggap lebih mendekati kinerja pada otak manusia. Proses aktivasi algoritma selama iterasi dapat dipantau dan dilihat pola pergerakannya.

Berbeda dengan strategi ANN yang berusaha mencari *hyperplane* pemisah antar *class*, SVM berusaha menemukan *hyperplane* yang terbaik pada *input space.* Prinsip dasar SVM adalah *linear classifier*, dan selanjutnya dikembangkan agar dapat bekerja pada problem non-linear, dengan memasukkan konsep *kernel trick* pada ruang kerja berdimensi tinggi. Perkembangan ini mendorong penelitian di bidang pemodelan untuk menggali potensi kemampuan SVM, baik secara teoritis maupun dari segi aplikasi.

2.4.4 Interpretasi Model

Model ini disusun dengan tingkat kepercayaan tingkat 95% sesuai dengan distribusi t-student. Semua model DM dengan algoritma ANN, SVM, dan MR di-*training* menggunakan 12 atribut variabel *input*. Tabel 2.2 menunjukkan kapasitas prediksi semua model hasil *training,* membandingkan kinerjanya dalam memprediksi nilai IRI berdasarkan MAD, RMSE dan R^2. Tabel ini menunjukkan bahwa nilai IRI dapat diprediksi secara akurat oleh masing-masing dari tiga model DM, terutama oleh ANN dan SVM model. Ketiga model pilihan tersebut merupakan model yang cukup sering digunakan dengan menggunakan algoritma rminer.

Tabel 2.2. *Error metrics* model DM

Model	MAD	RMSE	R^2
MR	0.89 ± 0.00	1.13 ± 0.00	0.62 ± 0.00
ANN	0.67 ± 0.03	0.81 ± 0.04	0.87 ± 0.01
SVM	**0.53 ± 0.01**	**0.71 ± 0.03**	**0.91 ± 0.02**

Tabel tersebut memperlihatkan *standard error* dan R^2 untuk setiap model yang dikembangkan. Model DM dengan algoritma SVM memiliki nilai MAD dan nilai RMSE terkecil sekaligus memiliki nilai R^2 tertinggi. Model prediksi dengan algoritma ANN dan SVM dapat diterima dan memiliki peluang untuk dipergunakan dalam menghitung prediksi kinerja jalan karena memiliki R^2 lebih dari 0.70. Dalam penelitian ini, selanjutnya model prediksi kinerja jalan yang digunakan adalah model DM dengan algoritma SVM.

Selanjutnya, ilustrasi kurva REC digunakan untuk menggambarkan lima model berbeda yang terdiri dari dua model eksisting dan tiga model usulan seperti dapat dilihat pada gambar 2.6. Dalam kurva tersebut terlihat bahwa model SVM memiliki nilai akurasi tertinggi dengan nilai tolerasi terkecil yang bergerak secara konsisten. Model HDM-IV yang digunakan sempat memiliki nilai akurasi yang tinggi, namun tidak bergerak konsisten untuk setiap nilai toleransi yang diiterasikan. Kurva REC ini menggambarkan keseluruhan proses iterasi dengan *run* 20 kali pada model SVM dengan *hyperparameter* terbaik untuk mencapai model SVM yang *fit* menggunakan ϵ = 0.07 $\pm$ 0.01 dan γ = 0.05$\pm$0.00. Sedangkan *hyperparameter* untuk ANN adalah H = 3 $\pm$ 1. Bentuk kurva REC dapat berubah bentuk apabila menggunakan *hyperparameter* yang berbeda dan jumlah *runs* iterasi berbeda pula.

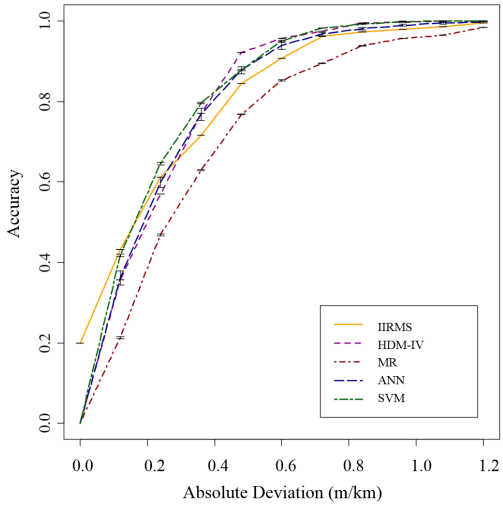

Gambar 2.6. Kurva REC seluruh model

Hasil interpretasi model prediksi kinerja jalan yang telah dikembangkan menghasilkan model SVM merupakan model dengan tingkatan akurasi tertinggi. Pada bagian selanjutnya dalam penelitian ini, model DM dengan algoritma SVM digunakan sebagai pemodelan utama untuk prediksi kinerja jalan, optimasi dan modul DSS.

2.4.5 Kontribusi Variabel

Model DM yang dikembangkan dapat menilai tingkat kontribusi setiap variabel dan atribut yang menjadi *data input* dalam model. Seluruh atribut yang menjadi *input data set* dikelompokan menjadi tiga dimensi, yaitu *initial performance*, *traffic*, dan *distress*.

Sebuah vektor parameter dalam model DM ini dipilih untuk menjelaskan bahwa merupakan fungsi peragam dan bukan parameter-parameter sebagaimana dalam pendekatan parametrik. Satu-satunya syarat bagi sebuah fungsi peragam adalah mampu membangkitkan sebuah matrik ragam peragam yang definit non negatif. Terdapat beberapa metode yang dapat digunakan untuk menduga nilai-nilai *hyperparameter*. Nilai θ dapat diduga dalam DM ini dengan menggunakan metode metode *cross validation*. *Hyperparameter* yang digunakan (H and γ) adalah H (2, 4, ..., 10) dan γ (2-15, 2-13, ..., 23). Nilai tersebut menghasilkan model paling presisi dengan waktu *run* yang cukup optimal. Untuk pengembangan model selanjutnya dapat digunakan pendekatan dengan mencoba nilai *hyperparameter* lainnya. Kontribusi setiap atribut dan dimensi merupakan *relative importance* dalam penyusun model. *Script* untuk mendapatkan nilai kontribusi ini disusun sebagai berikut:

```
mgraph (y=SVM, x = NULL, graph="IMP",
leg = c("initial","traffic","distress","patching"), xval = -1, PDF = "", PTS = -1,
size = c(5, 5), sort = TRUE, ranges = NULL, data = NULL,
digits = NULL, TC = -1, intbar = TRUE, lty = 1, col = "black",
main = "", metric = "MAE", baseline = FALSE, Grid = 0,  axis = NULL)
```

Kontribusi individu setiap atribut dan dimensi pembentuk model prediksi kinerja jalan ditunjukkan pada tabel 2.3.

Tabel 2.3. *Relative importance* atribut model prediksi IRI

Input/Atribut	Dimensi	Relative Importance (%)		
		ANN	SVM	MR
IRI	Initial Performance	11.50	14.20	9.40
age	Traffic	13.50	15.10	9.10
ESAL		26.30	24.50	25.20
Pothole	Distress	8.50	9.20	7.70
Seal Patching		2.00	1.80	4.10
Structural Patching		4.00	6.00	2.10
Alligator Crack		3.20	4.80	6.10
Irregular Crack		4.00	7.10	5.20
Block Crack		5.10	3.90	7.30
Long Crack		14.20	10.20	9.40
Rut		5.50	2.10	6.10
Deformation		2.20	1.10	8.30

Hasil pencarian nilai kontribusi dalam DM dapat disederhanakan dan ditampilkan dalam gambar 2.7 yang menampilkan *relative importance* pada sumbu-x untuk setiap atribut dan dimensi pada sumbu-y pembentuk model prediksi kinerja jalan dengan pendekatan model DM menggunakan algortima SVM, ANN, dan MR. setiap atribut memiliki relative importance yang berbeda. Hal tersebut didorong oleh sensitivitas dan karakter masing-masing model dalam merespon setiap perubahan data yang diterima. Seluruh model yang ditawarkan memiliki kelebihan dan kekurangan masing-masing, serta memiliki kekuatan tertentu pada bidang dengan kompetensi yang berbeda.

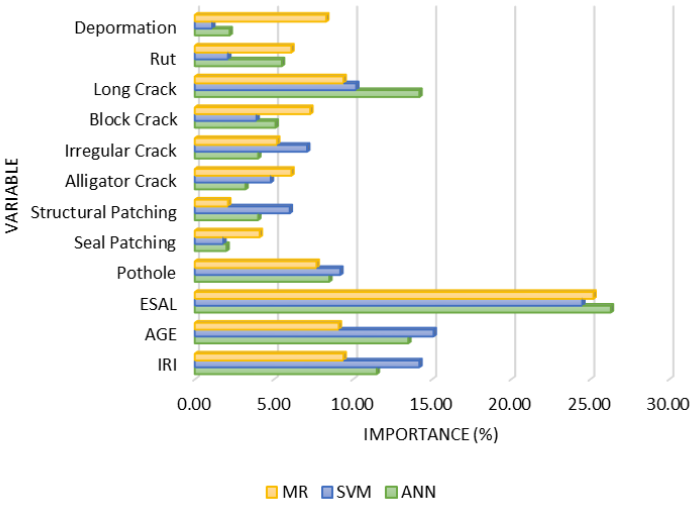

Gambar 2.7. *Relative importace* setiap atribut

Analisa model selanjutnya adalah menyusun algoritma untuk memilih dimensi utama yang mempengaruhi model prediksi kinerja jalan sekaligus menganalisa variabel pendukung yang mempengaruhi model prediksi kinerja jalan yang tidak terakomodir dalam model ini. Algoritma disusun dengan menggunakan *script* yang dimasukan kepada perintah *package rminer* berupa menu VEC, yaitu sebagai berikut:

```
mgraph(y=SVM, x = NULL, graph="VEC", leg = NULL, xval = -1, PDF = "", PTS = -1,
        size = c(5, 5), sort = TRUE, ranges = NULL, data = NULL,
        digits = NULL, TC = -1, intbar = TRUE, lty = 1,
col = "black", "red", "green", "blue"
        main = "", metric = "MAE", baseline = FALSE, Grid = 0,
        axis = NULL)
```

Hasil analisa VEC menggambarkan pengaruh atribut utama yang bergerak secara dinamis dalam model prediksi kinerja jalan dengan model SVM ini berupa ESAL yang merupakan kelompok dimensi *traffic*, *ditress*, *structural patch* dan *seal patch*. Penurunan IRI mengikuti pertambahan ESAL dan perkembangan *distress*, dan sebaliknya IRI membaik disaat dilakukan tindakan *patching,* baik itu *structural patch* maupun *seal patch*. Melalui kurva VEC yang dihasilkan, dapat digambarkan bahwa ESAL yang merupakan kelompok dimensi memiliki gerakan dinamis yang terbaca nyata saat IRI mencapai skala 5.0 m/km yang selanjutnya bergerak secara cepat bahkan melampaui atribut distress. Sedangkan atribut *distress* mulai mempengaruhi penurunan IRI sejak awal (*initial performance*) kemudian menurun disaat skala atribut mencapai 0.6. Perubahan ini didukung oleh tindakan pemeliharaan jalan berupa *patching*, yang tergambar memiliki hubungan dinamis cukup baik dan mampu memperbaiki nilai IRI.

Model DM dengan algoritma SVM yang digunakan dalam penyusunan kurva VEC ini menunjukan pengamatan bahwa hampir seluruh atribut memiliki *hubugan nonlinier* dengan IRI. Sebagai data empiris dalam model ini ditunjukan bahwa *patching* memiliki

dampak positif dalam prediksi IRI. Di sisi lain, peningkatan *pothole, crack, longcrack, dan depression* terlihat menurunkan nilai IRI. Ini menujukan bahwa dampak negatif dalam perilaku IRI dapat dikurangi dengan berbagai tindakan perbaikan jalan secara menerus dan konsisten.

2.4.6 Analisis Sensitivitas

Analisis sensivitas ini merupakan analisis yang dilakukan untuk mengetahui akibat dari perubahan atribut *input* terhadap perubahan nilai IRI. Dengan melakukan analisis sensitivitas maka akibat yang mungkin terjadi dari perubahan tersebut dapat diketahui dan diantisipasi sebelumnya. Berikut adalah *script* yang digunakan untuk analisis sensitivif yang dikembangkan.

```
Mdls[[1]]$IMP <- Importance(Mdls[[1]]$FM,
        data = Mdls[[1]]$bd, # your data just with the input variables
        RealL = 12,
        method = "sensg",
        measure = "gradient",
        sampling = "regular",
        baseline = "mean",
PRED = NULL,
```

Pada gambar 2.8 dapat dilihat hasi analisis sensitivitas. *Package* yang digunakan *global sensitive analysis* (GSA). Gambar 2.8.a. memperlihatkan hubungan ESAL, waktu (*t*) dan IRI. Jumlah ESAL yang tinggi menyebabkan penurunan IRI hanya dalam waktu singkat. Hal tersebut memberikan beragam kesimpulan. Salah satunya adalah jalan dengan ESAL yang besar, memerlukan manajemen pemeliharaan khusus, tidak bisa ditangani dengan pendekatan standar.

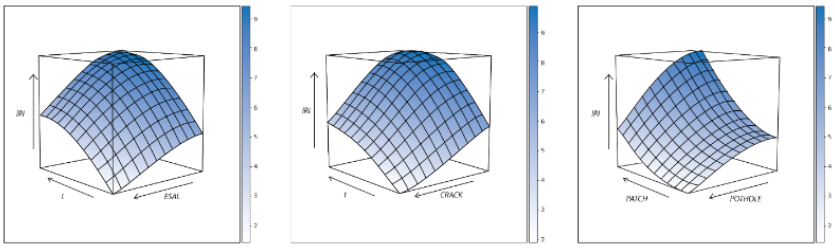

(a) (b) (c)

Gambar 2.8. Interaksi antar variabel

Selanjutnya pada gambar 2.8b terlihat interaksi antara *crack* dan t sehubungan dengan prediksi nilai IRI. *Crack* dan t secara bersamaan memberikan pengaruh yang besar terhadap perubahan nilai IRI. *Crack* secara individu pertumbuhannya pun berkembang mengikuti fungsi t. Secara utuh analisis sensitivitas dalam hubungan ini adalah t tidak langsung mempengaruhi IRI namun secara langsung mempengaruhi *crack*.

Pertumbuhan *crack* seiring waktu perlu diperhatikan dan ditangani dengan baik. *Crack* memiliki proses *distress* ikutan apabila tidak ditangani segera. Kondisi *crack* yang dibiarkan dapat menimbulkan retakan lebih besar, infiltrasi air permukaan dan mendorong terjadinya *pothole* pada permukaan jalan. Gambar disamping menunjukkan *patch* dan *pothole* yang menunjukan interaksi dengan dampak tinggi dari atribut *pothole* dan panjang retak dengan *patch* seperti diperlihatkan pada gambar 2.8c.

Melalui pendekatan analisis sensitivitas dengan menggunakan algoritma SA dan GSA, didapatkan perubahan pengaruh setiap atribut dalam setiap iterasi yang dilakukan. SA dan GSA dapat digunakan untuk mengetahui sifat dasar pemodelan berupa *behavior model* terhadap tingkat kinerja jalan pada kondisi sesungguhnya.

2.5 Pengembangan Model Optimasi Pemeliharaan Perkerasan Jalan

Model optimasi dikembangkan dengan aspek-aspek yang terstruktur dan terukur dari proses pengambilan keputusan, sementara teknik AI diarahkan untuk menyusun fitur kualitatif dari keseluruhan proses, yang biasanya dilakukan oleh para ahli. Dengan demikian, mengintegrasikan kekuatan AI dan optimasi tampaknya menjadi cara yang tepat untuk meningkatkan kemampuan optimasi dan DSS, pada bagian ini diusulkan sebuah model optimasi pemeliharaan perkerasan jalan dengan pendekatan MOO berbasis GA dengan pangkalan data hasil pengembangan DM. Pendekatan ini dirancang untuk menyusun dan menunjukkan bahwa AI dan DM mampu memberikan solusi praktis dalam penyusunan DSS sistem manajemen jalan.

2.5.1 Arsitektur dan Simulasi Model

Upaya awal untuk mengintegrasikan AI dan model optimasi tradisional didasarkan pada pengetahuan ahli dan praktisi sistem manajemen perkerasan jalan. Pengetahuan dalam sistem ini disimpan dalam cara yang relatif sederhana sehingga memudahkan penggunaan dalam berbagai kondisi. Namun, *traditional expert system* dibatasi aturan terstruktur yang telah digunakan dalam aturan organisasi yang berjalan. Dalam sudut pandang ini, meskipun hal ini dapat digunakan sebagai alat *decision support* dalam kasus sederhana, namun tidak memanfaatkan secara penuh kemampuan teknik AI terbaru, seperti DM dan *metaheuristik*.

Model prediksi kinerja jalan berbasis DM dikombinasikan dengan metode optimasi diharapkan mampu melakukan ekstraksi data dan analisis dalam menentukan serta memilih solusi terbaik untuk optimasi. Sistem yang diusulkan mengintegrasikan kemampuan untuk menerima data baru dan segera beradaptasi dengan *learning* secara *real time*. Pendekatan ini memberikan kemampuan kepada sistem untuk bekerja lebih dinamis, pada setiap perubahan kondisi. Meskipun tidak ada aplikasi praktis yang dikembangkan dalam implementasi teknik sipil sejauh ini, ide menggabungkan DM dengan optimasi akan dibahas lebih lanjut. Aplikasi optimasi pemeliharaan perkerasan

jalan dapat dibagi menjadi beberapa modul sistem. Pada tabel berikut dapat dilihat modul, aplikasi dan kegunaannya.

Komponen yang dikembangkan dalam lingkungan R dan DM dan memiliki hubungan dengan sistem optimasi ini dapat dibagi menjadi dua bagian. Bagian pertama terdiri dari *convensional expert system*, yang bertujuan untuk mengklasifikasikan jenis dan pola pemeliharaan menggunakan *logic rule* (terutama berdasarkan fungsi "*if*"). Hal tersebut mengikuti klasifikasi manajemen pemeliharaan jalan, menggunakan prosedur yang tetap seperti dapat dilihat pada gambar 2.9.

Tahapan strategi dan pilihan jenis pemeliharaan yang telah diuraikan dalam dalam gambar tersebut kemudian dapat diterjemaahkan dalam kutipan *script code* berikut yang merupakan bagian dari pengembangan model dengan pendekatan MOO dengan GA:

```
Family<-readline("Qual  a family the maintenance (pneus[P] / choice the typical [M] / loop the maintenance [M+1] / anual[SP])?")
        if (Family==”P”) {
        IRI<-as.numeric(readline("Qual a rupiah m/km (IRI)?”))
                if (0<=IRI &&IRI<4.0) Classe<-“P1”
        else if (4.0<=IRI && IRI<=6.0) Classe<-“P2”
        else if (IRI>6.0) Classe<-“P3”}
```

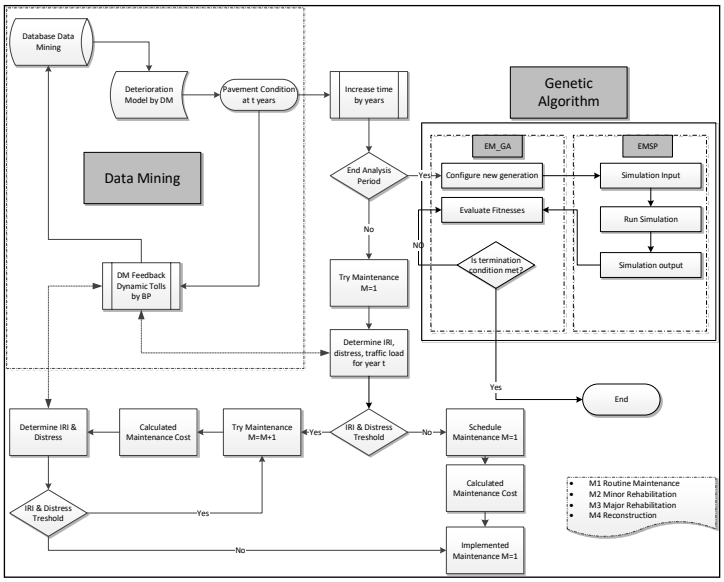

Gambar 2.9. Tahapan optimasi pemeliharaan

Klasifikasi kondisi perkerasan jalan dengan pengukuran kinerja jalan dalam skala IRI merupakan kerangka besar untuk menilai kinerja jalan secara utuh. Sedangkan tahapan optimasi harus dilakukan secara detail dan mendasar. Data histori dan data hasil survei visual dapat digunakan sebagai atribut *input* model optimasi. Sistem ini menuntut data yang cukup besar dan berurutan serta informasi jenis dan jadwal pemeliharaan jalan yang sudah dilaksanakan. Bahkan, pengguna harus memberikan informasi mengenai kondisi IRI tiap segmen yang berbeda untuk berbagai posisi geometri.

2.5.2 Definisi Objective Functions dan Constraint

Bagian ini menguraikan pernyataan matematika dari masalah dalam penelitian ini dengan memberikan formulasi MOO secara rinci. Untuk mendapatkan optimasi dalam sistem manajemen pemeliharaan jalan ada dua fungsi utama yang harus dapat dicapai, yaitu:

1. *Objective 1*: meminimalkan biaya pemeliharaan
2. *Objective 2*: memaksimalkan kondisi perkerasan jalan

Pada saat masing-masing *objective* beridiri sendiri, keduanya dalam bentuk linier, sehingga masalah dapat dipertimbangkan sebagai masalah *linear objective problem*. Namun saat pengambil keputusan mempertimbangkan *objective* tambahan dalam bentuk *non-linear*, maka pendekatan optimasi pun berubah menjadi *non-linear* MOO. Sebagai contoh, pembuat keputusan mungkin ingin memberikan kelancaran jaringan jalan raya secara merata, kemudian ditambahkan *objective* lainnya berupa pencapaian *roughness index* jaringan jalan. Dua *objective* tersebut tidak dapat ditempatkan dalam persamaan linier secara bersamaan, namun berupa *non-linear* MOO. Kondisi kinerja jalan setiap ruas, seringkali memiliki perbedaan yang signifikan dengan kinerja jalan pada tingkat jaringan. Kondisi tersebut menjadi tambahan *constraint* tersendiri untuk dapat dipetakan.

Untuk menyelesaikan masalah ini, semua *objective* dibatasi oleh *constraint*. Jenis dan nilai *constraint* tergantung pada kebijakan lembaga penyelenggara jalan. Menurut Bail dan Labi (2009) *constraint* tersebut biasanya dalam bentuk sebagai berikut:

a. *Constraints on performance measure*. Seringkali pembuat keputusan menginginkan tingkat kinerja jaringan jalan dapat mencapai target yang ditentukan. Namun jaringan yang terdiri dari beberapa segmen tersebut terkadang memiliki hambatan internal berupa perbedaan kondisi dan target masing-masing segmen dalam jaringan tersebut. Target dan kondisi dalam jaringan harus didefinisikan terlebih dahulu dan mampu diterjemahkan dalam formula matematika secara utuh.
b. *Constraints on budget*. Kebutuhan untuk menjaga kinerja perkerasan sesuai dengan target yang telah ditetapkan seringkali terhambat oleh ketersediaan anggaran. Setiap segmen, bahkan jaringan harus berbagi dengan segmen dan jaringan lain untuk memanfaatkan anggaran.
c. *Constraints on policy,* Dalam pelaksanaan sistem manajemen perkerasan jalan, tindakan yang bisa diambil sangat tergantung pada kebijakan yang ditentukan oleh para lembaga pemegang kebijakan. Selain kebijakan anggaran, seringkali pelaksanaan pemeliharaan perkerasan jalan dibatasi juga oleh kebijakan politik berupa penentuan prioritas berdasarkan pertimbangan tertentu (bukan pertimbangan teknis). Kondisi serupa terjadi di negara berkembang seperti Indonesia. Kebijakan yang sedang berproses ke arah yang lebih baik, sementara ini harus melalui jalan berliku terlebih dahulu, proses edukasi dan pendewasaan diri dalam penentuan anggaran yang tepat memerlukan dukungan keilmuan dan pendekatan akademik lainnya.

2.5.3 Pavement Performance Maximization

Penelitian ini dilakukan dengan pendekatan MOO, yaitu memaksimalkan tingkat pelayanan yang diukur dengan IRI dan meminimalkan biaya pemeliharaan. Selanjutnya, model yang dikembangkan dengan mempertimbangkan variabel muatan berlebih dan *cost life cycle* dalam anggaran tahun tunggal dan tahun jamak. Nilai IRI yang lebih kecil menunjukkan kondisi permukaan jalan lebih baik, dalam persamaan berikut, memaksimalkan nilai IRI menggunakan notasi [Min].

Maximize:

$$Min\left(\frac{1}{\sum_{i=1}^{n} d_i}\right) * \sum_{i=1}^{n}\left(d_i * \sum_{j=1}^{m} IRI_{ij}^{1} * x_{ij}\right) \quad \text{.....2.3}$$

Subject to:

$$\sum_{j=1}^{m} IRI_{ij}^{1} * x_{ij} \leq IRI_{ui} \ \forall i \in \{1, \ldots, n\} \quad \text{.....2.4}$$

$$\sum_{i=1}^{n} \sum_{j=1}^{m} c_{ij} * x_{ij} \ \leq B \quad \text{.....2.5}$$

$$\sum_{j=1}^{m} x_{ij} = 1 \ \ \forall i \in \{1, \ldots, n\} \quad \text{.....2.6}$$

Dimana

C_{ij}	=	*cost parameter of treatment j selected to pavement segment i*
d_{ij}	=	*distance weight parameter to pavement segment i*
IRI_{ij}^{1}	=	*roughness IRI value one year later for treatment j applied to pavement segment i*
IRI_{ui}	=	*unacceptable IRI level for each individual pavement segment i*
B	=	*budget level for pavement network maintenance*
x_{ij}		*1 → if treatment j selected to pavement segment i* *0 → if treatment j not selected to pavement i*
n	=	*total number of pavement segment of the network*
M	=	*total number of pavement management treatment options*

Dalam permasalahan di atas, dijelaskan bahwa tujuan dari optimasi ini adalah untuk mendapatkan kondisi jalan dengan IRI maksimal (skala IRI minimal) seperti yang tertulis dalam persamaan (2.3) dengan memanfaatkan anggaran yang terbatas seperti ditulis dalam persamaan (2.5). Untuk mencapai tujuan tersebut, perumuskan formula pelayanan pemeliharaan dengan menggunakan pendekatan jenis dan biaya pemeliharaan standar. Biaya total yang diperlukan dan rata-rata IRI dalam jaringan jalan adalah dua *objective* yang dipertimbangkan. Sedangkan total anggaran, nilai minimal IRI setiap segmen, dan waktu pelaksanaan secara bersamaan adalah *constraint* yang didefinisikan. Untuk menemukan pola optiamsi melalui pendekatan *Pareto optimal solutions*, diperlukan tahapan mengkonversi MOO menjadi masalah SOP terlebih dahulu. Langkah tersebut diperlukan sebagai strategi untuk mendapatkan

solusi matematika yang lebih sederhana. Pendekatan tersebut dapat dilihat dalam persamaan sebagai berikut:

Maximize:

$$\left(\frac{1}{\sum_{i=1}^{n} d_i}\right) * \sum_{i=1}^{n}\left(d_i * \sum_{j=1}^{m} IRI_{ij}^{1} * x_{ij}\right) \leq \ average_{IRI} \quad \text{.....2.7}$$

Dimana $average_{IRI}$ = *Predefined pavement network average IRI level*

2.5.4 Maintenance Cost Minimization

Selain memaksimalkan kinerja jalan dengan nilai target IRI terendah, penyelenggara jalan juga harus meminimalkan anggaran yang digunakan untuk biaya pemeliharaan. Dalam persamaan berikut, hal tersebut dijelaskan bahwa anggaran yang digunakan untuk pemeliharaan tergantung pada biaya unit dikalikan dengan panjang jalan segmen. Pada kenyataannya biaya persatuan Panjang segmen pun memiliki perbedaan, namun dapat diambil rata-ratanya.

Minimize:

$$Min \sum_{i=1}^{n} \quad \sum_{j=1}^{m} C_{ij} * x_{ij} \quad \text{.....2.8}$$

Subject to (2.4), (2.5), & (2.6)

Dimana C_{ij}= *cost parameter of treatment j selected to pavement segment i*

2.5.5 Uji Model Optimasi

GA sendiri dapat digunakan untuk menemukan *Pareto solution* untuk sistem manajemen perkerasan secara langsung. Pareto sangat jamak digunakan dalam teori optimasi dalam berbagai disiplin bidang ilmu. Mengkompromikan berbagai kendala untuk mencapai target tertentu tentu bukanlah hal yang sederhana, sehingga diperlukan pendekatan yang menyeluruh dan tepat sasaran. Bantuan model matematika tentunya akan banyak membantu mempermudah menyusun model optimasi. Namun pengambilan keputusan pasca-optimasi masih memerlukan metode lanjutan yang dapat digunakan untuk memilih solusi akhir. Solusi akhir tersebut dapat diilustrasikan selama penerapan model. Untuk menyederhanakan masalah, nilai skala IRI yang dapat diterima pada setiap segmen jalan ditetapkan 4.0 m/km; dengan panjang segmen menyesuaikan aktual di lapangan. Solusi yang diperoleh dengan menggunakan algoritma dengan menyederhanakan MOO menjadi SOP terlebih dahulu dapat dilihat kurva VEC pada gambar 2.10 (kiri). Pemodelan dijalankan dengan pemisahan strategi pemeliharaan. Masing-masing strategi diskenariokan sebagai awal pemeliharaan (M1, M2, M3, dan M4) menggunakan anggaran maksimal. Sumbu-x menunjukan persentase penambahan anggaran maksimal, dan sumbu-y menunjukan nilai IRI yang dapat dicapai pada setiap jenis stratgi pemeliharaan. Gambar tersebut menunjukan bahwa model bergerak secara dinamis, dengan menjalakan *objective* tunggal namun berulang.

Untuk menguji model dengan pendekatan MOO digunakan data yang sama dan dibandingkan tingkat akurasi optimasinya antara model dengan pendekatan MOO dan SOP. Strategi pemeliharaan tetap sama dengan sebelumnya, namun untuk MOO digunakan strategi pilihan bersama, dan membiarkan GA memilih strategi yang ada melalui proses evolusi. Strategi pemeliharaan yang dinilai tidak cocok untuk jenis kondisi jalan dimaksud, dengan sendirinya dapat diabaikan dan melangkah pada strategi selanjutnya.

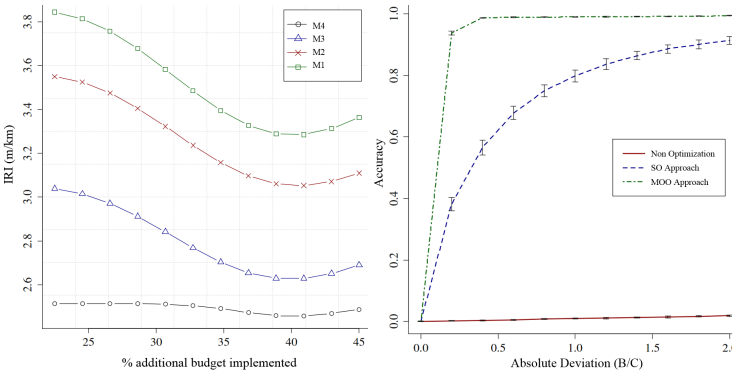

Gambar 2.10. Kurva VEC dan REC model optimasi

Proses evolusi ini mendekati proses yang sudah diuraikan dalam diagram alir pada gambar 2.10. Setelah dilakukan simulasi dengan pendekatan MOO dan empat pendekatan SOP sebagai kelanjutan simulasi sebelumnya, perbandingan tingkat akurasi pemodelan dapat dilihat kurva REC pada gambar 2.10 (kanan). Terlihat dalam gambar di atas bahwa MOO memiliki nilai akurasi yang tinggi dibandingkan dengan simulasi SOP untuk setiap strategi. Sedangkan capaian dengan non optimasi memiliki nilai akurasi sangat rendah. Selanjutnya model MOO dengan pendekatan GA akan digunakan untuk tahapan optimasi.

2.6 Konsep Decision Support System

Konsep pengembangan DSS dalam penelitian ini bertujuan untuk memberikan gambaran implementasi integrasi antara DM, optimasi, dan GIS. Menggunakan pendekatan GIS dengan piranti lunak *open source* diharapkan pengembangan DSS semakin menarik untuk dikembangkan. Konsep ini berupa model sebagai aplikasi antar muka yang mampu menerima *input* berupa *numeric* dan koordinat kemudian memberikan *output* berupa *text*, *numeric*, tabular, dan grafis.

2.6.1 Pengembangan Modul GIS

Dalam rangka pengembangan sistem analisis DSS untuk optimasi pemeliharaan perkerasan jalan diperlukan pengembangan modul berbasis GIS. Beberapa fungsi GIS yang dikembangkan dan ditampilkan dapat diterapkan pada sistem yang sudah

terbangun. Modul GIS yang dikembangkan ini telah terintegrasi dengan DM. Bab ini berisi beberapa fitur selain fungsi tampilan grafis dan laporan. Fungsi modul GIS yang telah dikembangkan meliputi kemampuan sebagai berikut:

1. Intregrasi kebutuhan analisis hasil dan informasi grafis dalam peta dinamik GIS.
2. Memungkinkan engineer untuk melakukan analisis what-if berbasis peta untuk mengeksplorasi berbagai alternatif dan kombinasi yang sulit dihasilkan jika tidak menggunakan peta GIS.
3. Memungkinkan engineer untuk melakukan perubahan pada tahun, lokasi dan metode penanganan secara langsung pada peta.
4. Menyajikan pengaruh implementasi pemeliharaan tingkat ruas dan tingkat jaringan dengan peta modifikasi.

GIS memiliki tiga fungsi penting dalam bentuk *layer* yang terhubung secara dinamik dengan modul analisis prediksi kinerja jalan dan optimasi pemeliharaan. Ketiga fungsi penting tersebut berada pada satu sistem utuh DSS seperti dapat dilihat pada gambar 2.11. Tiga fungsi penting yang dikembangkan dalam sistem ini adalah *Linear reference system* (LRS) dan GIS *base map preparation function; Spatial analysis* dan *visualization function*; dan *Analysis interactive map-based multi-year*.

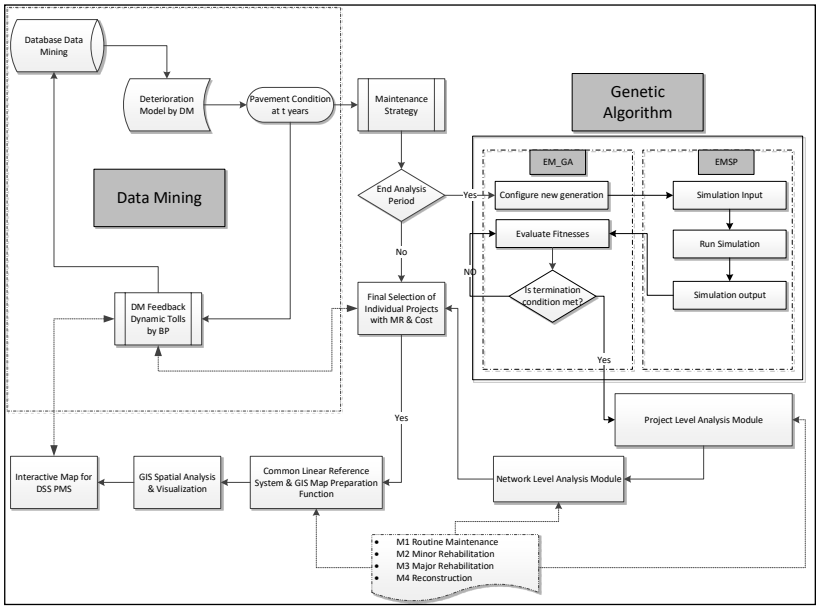

Gambar 2.11. Konsep pengembangan *interface* DSS

Secara umum, Peta GIS berisikan beberapa *layer* atau lapisan informasi. Setiap *layer* informasi mewakili satu set atribut dari obyek dunia nyata (*real world*). Dalam Modul GIS ini, beberapa *layer* dasar peta GIS diambil dari Direktorat Jenderal Bina Marga Kementerian Pekerjaan Umum dan Perumahan Rakyat. Peta tersebut termasuk jalan nasional dan batas wilayah administrasi. Peta dasar juga berisi informasi grafis dari jalan raya dan beberapa batas administrasi hukum, tetapi belum mengandung informasi

tentang kinerja jalan. Integrasi informasi grafis pada peta GIS dengan pangkalan data IIRMS dan kebutuhan analisis memungkinkan untuk melakukan modifikasi dan memverifikasi secara visual dengan efektif.

Meskipun aplikasi *software* GIS, seperti *GIS lisboa series* dan *ArcInfo* menyediakan beberapa fungsi umum, *software* tersebut tidak didesain secara khusus untuk sistem manajemen perkerasan jalan. Dalam implentasi nyata tidak mudah untuk menggunakan *software* GIS dan pangkalan data tanpa pemahaman yang mendalam tentang keduanya. Salah satu kontribusi pengembangan modul GIS adalah kemampuannya untuk menganalisa berbagai tingkatan dari analisis keperluan dengan menghubungkan perbedaan tingkatan dari analisis secara otomatis dan menghubungkannya secara dinamik dengan *layer-layer* peta.

LRS dan GIS *base map preparation function* yang ditampilkan dalam penelitian ini digunakan untuk mengintegrasikan analisis sistem manajemen perkerasan jalan yang dihasilkan dari data IIRMS dengan informasi grafis dalam peta GIS. Teknologi *modified dynamic segmentation* (MDS) telah dikembangkan untuk menghasilkan *layer* peta baru berdasarkan pada peta *route* jalan dan *output* yang dihasilkan dari modul *project-level analysis* menggunakan LRS. Metode *addrelate* digunakan untuk menghubungkan hasil analisis DM, termasuk data IRI. Model MDS dan metode *addrelate* dikembangkan untuk mengembangkan fungsi tersebut dan data yang ditampilkan pada peta GIS akan dipresentasikan pada sub-bab berikut.

GIS menyediakan kemampuan untuk menghasilkan analisis spasial dan visualisasi data. Fungsi GIS analisis spasial dan visualisasi dikembangkan untuk mendukung *output* yang dihasilkan dari analisis keperluan sistem manajemen perkerasan jalan. Beberapa hasil analisis dapat dianalisa secara spasial dan ditampilkan pada peta GIS secara langsung dan dinamik menggunakan fungsi analisis spasial dan visualisasi. Beberapa contoh yang ditampilkan berikut ini untuk menggambarkan integrasi dan keuntungan menggunakan fungsi GIS yang dikembangkan dalam modul GIS untuk analisis pemeliharaan perkerasan jalan.

GIS memberikan kemampuan secara penuh dalam visualisasi dan pemetaan yang sangat berguna dalam analisis kebutuhan pemeliharaan perkerasan jalan. Dalam kaitannya untuk menfasilitasi DSS pada analisis kebutuhan *multi-years*, beberapa fungsi lanjutan telah dikembangkan. Konsep desain dari fungsi tersebut adalah untuk menfasilitasi analisis kebutuhan pemeliharaan perkerasan jalan menggunakan visualisasi GIS.

2.6.2 Fitur Poligon

Metode *Addrelate* yang disediakan oleh GIS digunakan untuk menampilkan fitur peta poligon. Metode ini membuat hubungan antara informasi grafik dalam *layer* peta dan catatan data yang dihasilkan dari analisis kubutuhan hasil. Gambar 2.12 menampilkan hasil rata-rata IRI tahun 2014 dari 6 provinsi. Provinsi dapat diasosiasikan dengan sebuah peta poligon dan ditampilkan menggunakan metode *AddRelate*. *Engineer* dapat mencari kembali peringkat kinerja jalan dalam analisis kebutuhan dengan meng-klik pada peta.

Kemudian *GIS base Map Preparation function* secara otomatis mengekstrak peringkat kinerja pada semua *project pavement* yang terkait dengan masing masing provinsi, menghitung peringkat rata-rata kinerja pada setiap jaringan jalan dan membuat *composite rating filed* untuk tahun tertentu pada tabel yang ditunjukkan sisi kanan gambar 2.12.

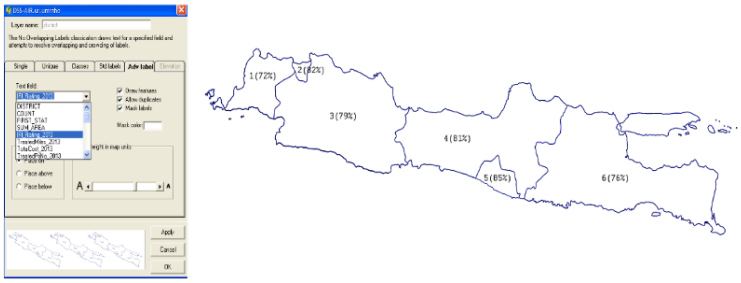

Gambar 2.12. Contoh metode *AddRelate*

Hal ini juga secara otomatis membuat *layer* peta setiap batas administrasi yang diinginkan, yang ditunjukkan pada sisi kiri gambar 2.12 terdapat *field location* pada kedua tabel. *Field* unik ini mengidentifikasi setiap *record* pada peta dan tabel hasil. Metode *AddRelate* menggunakan *field* ini untuk membuat hubungan antara *layer* peta dan tabel hasil dan membuat *record* baru yang berisi semua *record* dari *layer* peta dengan semua atribut yang berasal dari tabel hasil analisis.

2.6.3 Data Layer

Implementasi dilakukan pada tahapan dan layer tertentu. Terdapat lima *layer* peta dasar yang dapat digunakan dalam pengembangan modul GIS, yaitu sebagai berikut:

1. *Analysis result*: berisi detail dari *project-level*, termasuk peringkat *project* dalam analisis tahun berikutnya, metode penanganan dan biaya, AADT, informasi lokasi spasial seperti No.Segmen, No.Jaringan, NoProvinsi, No.Stasion, dan lainnya. Hal ini dibuat dengan metode MDS.
2. *Route*: *layer* ini disediakan oleh IIRMS. Setelah integrasi data, *layer* berisi informasi lengkap jalan nasional di Pulau Jawa.
3. *Area*: berisi detail informasi area penanganan balai di Pulau Jawa;
4. *Province*: berisi informasi batas wilayah IIRMS dan analisis kebutuhan hasil IIRMS *area-level*;
5. *Network*: berisi informasi batas jaringan jalan nasional.

Kelima *layer* peta dasar mencakup sebagian besar informasi yang dihasilkan dari model pemeliharaan yang dapat ditampilkan pada peta GIS. Hasil dari *Project-level analysis module* terhubung dengan informasi *project* yang ditampilkan pada *layer* hasil analisis dapat dilihat pada gambar 2.13. Hasil dari *network-level analysis module* berhubungan dengan area dan provinsi yang ditampilkan pada *layer* peta area dan provinsi

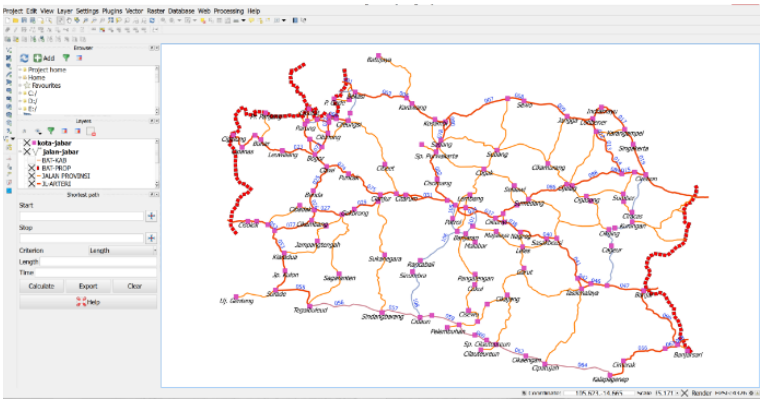

Gambar 2.13. Peta dasar modul GIS

2.6.4 Analisis Interaktif Pemeliharaan

Untuk memfasilitasi DSS pada analisis kebutuhan pemeliharaan perkerasan, kerangka analisis skenario optimasi pemeliharaan perkerasan jalan dikembangkan melalui integrasi kemampuan GIS dengan model analisis keperluan pemeliharaan, termasuk hambatan *project-level pavement* dan prediksi kinerja jalan. Fungsi analisis skenario *what-if* secara interaktif berdasarkan peta telah dikembangkan dan memberikan kesempatan kepada pengambil keputusan untuk dapat mengembangkan dan mengevaluasi skenario perbaikan yang berbeda secara intuitif dan langsung secara interaktif pada peta GIS.

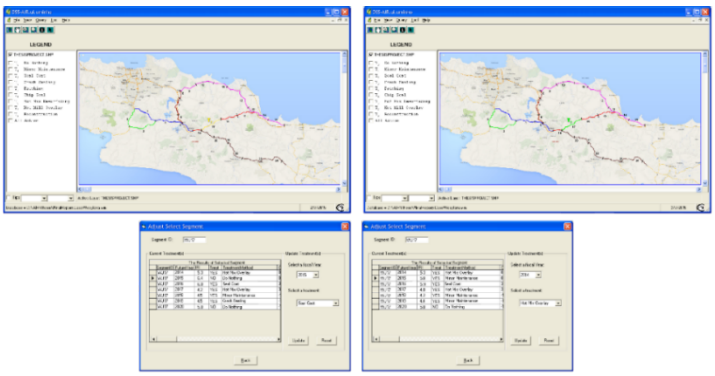

Gambar 2.14. Contoh analisis interaktif

Gambar 2.14 mengilustrasikan penggunaan analisis skenario pemeliharaan perkerasan jalan. Setelah program visual DSS menyelesaikan analisis prediksi kinerja jalan awal, aplikasi dikembangkan untuk menghasilkan pencatatan pada pangkalan data *project-level*, termasuk tahun perbaikan, lokasi, dan metode perbaikan. Hasil simulasi dalam tabel, hasil dapat juga ditampilkan dalam peta GIS, seperti pada gambar 2.14 (kanan-atas). *Engineer* dapat memahami dengan pengetahuan keteknikan untuk memperbaiki strategi pengelolaan yang dihasilkan oleh aplikasi DSS ini. Gambar 2.14

menunjukkan 2 ruas berdekatan yang dilakukan perbaikan yang sama dalam 2 tahun. Berdasarkan penilaian *engineer*, kedua ruas tersebut dapat dikelola dalam 2014 karena ruas tesebut berdampingan, dan jadwal tahun perbaikan tidak jauh berbeda menggunakan metode perbaikan yang sama. Keputusan yang baik dapat mengurangi biaya mobilisasi ruas dan kemacetan yang disebabkan oleh konstruksi dua ruas dalam tahun yang terpisah, bahkan dapat mereduksi biaya konstruksi total.

2.7 Studi Kasus Pemodelan Data Mining dan Optimasi Pemeliharaan Perkerasan Jalan di Indonesia

Jaringan jalan Indonesia (sekitar 500.000 km, dengan 40.000 km jalan beraspal nasional), saat ini kualitas tidak memadai, dengan beberapa kendala, terutama karena muatan berlebih. Sebagaimana diketahui, saat ini muatan berlebih di Indonesia, telah terjadi dalam berbagai kondisi dan makin mengganggu kinerja jalan (Hadiwardoyo, et al., 2012). Tingginya tingkat kerusakan infrastruktur jalan di negara-negara berkembang, ketatnya pembatasan anggaran, dan tingginya pertumbuhan lalu lintas, makin mendorong para penyelenggara jalan di berbagai negara untuk meningkatkan kinerja sistem manajemen perkerasan jalan (Rifai, et al., 2015b). Model prediksi kondisi perkerasan jalan memainkan peranan penting dan modal dasar untuk meningkatkan keberhasilan pemeliharaan perkerasan jalan (Karlaftis & Badr, 2015).

Jalan dengan muatan berlebih dianggap menjadi masalah umum di negara-negara berkembang (Ede, 2014). Masalah ini terus terjadi, dan pemerintah tampaknya tidak dapat mencegahnya. Faktor di balik terjadinya muatan berlebih adalah keterbatasan moda transportasi dan upaya meminimalkan biaya transportasi. Selain itu, perilaku penggunaan kendaraan dengan muatan berlebih secara menerus menyebabkan kerusakan semakain cepat. Dalam penelitiannya, Sianipar (2014) menyebutkan bahwa penyumbang terbesar terhadap penurunan kinerja jalan adalah muatan berlebih. Penurunan kinerja jalan akibat pembebanan normal dan pembebanan akibat muatan berlebih memiliki perbandingan yang tidak bersifat linear.

Dalam melaksanakan manajemen pemeliharaan jalan, DJBM telah mengembangkan IIRMS sebagai *tools* utama. Terdapat beberapa masalah yang ditemukan dalam sistem ini terkait dengan kualitas data yang kurang efisien dan relevansi output yang digunakan untuk penyusunan rencana dan program pemeliharaan. Data inti yang diperlukan oleh IIRMS disediakan oleh sejumlah survei yang biasanya dilakukan secara tahunan, seperti: inventarisasi jaringan jalan, *road condition survei* (RCS), serta pemeriksaan IRI (Bina Marga, 2012).

Menyusun model prediksi IRI merupakan masalah yang kompleks karena sifat dari kondisi perkerasan dan sejumlah besar parameter yang mempengaruhinya. Dengan demikian penggunaan AI, khususnya penerapan DM (Cortez, 2010), memiliki potensi yang besar dalam domain ini. Beberapa contoh aplikasi DM dalam domain teknik sipil telah dilakukan (Terzi, 2006) (Zhou, et al., 2010); (Tinoco, et al., 2011); (Parente, et al., 2014), dan (D'Andrea, et al., 2014). Dalam bagian ini akan diuraikan implementasi hasil pengembangan model prediksi IRI pada jalan nasional Indonesia berdasarkan data yang

telah dikumpulkan oleh IIRMS dan Hawkeye. Selanjutnya diuraikan perbandingan nilai IRI jalan nasional dalam kondisi pembebanan normal dan muatan berlebih

Keterbatasan biaya, jalan dengan muatan berlebih, luasnya jaringan jalan nasional, prioritas penanganan, skala waktu dan penjadwalan, dan pengaruh lingkungan merupakan tantangan tersendiri dalam mewujudkan kinerja jalan yang handal. Untuk melakukan optimasi pemeliharaan perkerasan jalan, telah berkembang berbagai pendekatan yang diakukan di berbagai negara. Mulai dari pendekatan tradisional sampai dengan pendekatan modern. Setiap metode memiliki kelebihan dan kekurangan masing-masing. Seiring waktu metode optimasi semakin lengkap dan memiliki pilihan beragam yang dapat disesuiakan dengan kondisi dan karakteristik yang ada. Beberapa tahun belakangan aplikasi dan implementasi GA berhasil menyelesaikan permasalahan berbasasis MOO (Elhadidy, et al., 2015). Pendekatan GA merupakan pendekatan yang cukup praktis dan telah banyak digunakan secara luas dalam berbagai bidang keilmuan. Melalui penekatan GA, diharapkan berbagai kondisi yang tidak diperkirakan di masa yang akan datang seperti ketidakpastian pertumbuhan lalu lintas dan beban jalan dengan muatan berlebih pada jaringan jalan nasional mulai dapat dipetakan dari awal sebagai bahan pertimbangan para pemegang kebijakan.

Optimasi dengan pendekatan GA dipilih sebagai alat utama untuk menyusun model optimasi pemeliharaan perkerasan jalan yang dikembangkan. Jaringan jalan nasional di Jawa Barat dipilih untuk menggambarkan hasil pemodelan dan kemudian divalidasi pada ruas jalan dengan muatan berlebih. Sejumlah pertimbangan yang harus diselesaikan dalam sistem manajemen perkerasan jalan, mendorong para pemegang kebijakan melakukan optimasi dengan menggunakan pendekatan MOO.

Dalam bagian ini akan diuraikan optimasi pemeliharaan jalan nasional dengan pendekatan GA. Pendekatan yang diusulkan diharapkan dapat meningkatkan kemampuan dan efisiensi modul optimasi sistem manajemen perkerasan jalan yang sudah ada. Penelitian ini khusus dilakukan pada optimasi penerapan pemeliharaan rutin, pemeliharaan berkala dan pemeliharaan khusus. Pola pemeliharaan yang tepat diharapkan dapat menjaga umur dan kinerja ruas jalan yang ada, terutama jalan dengan muatan berlebih. Bagian pertama menyajikan formulasi yang diusulkan sebagai implementasi pengembangan model awal. Bagian kedua menyajikan solusi dari masalah ini menggunakan GA. Bagian terakhir menunjukkan kelayakan pendekatan yang diusulkan menggunakan contoh studi jaringan jalan nasional dengan muatan berlebih.

2.7.1 Model Prediksi IRI

Model prediksi IRI hasil pengembangan model pada bagian ini diimplementasikan dengan data di Pulau Jawa dengan validasi di jaringan jalan Jawa Barat (WJ). Hasil prediksi IRI divalidasi pada 24 jaringan jalan di Jawa Barat dengan kode WJ-1 sampai dengan WJ-24. Sebagai gambaran, jaringan jalan di Jawa Barat dapat dilihat pada gambar 2.15. Jaringan jalan di Jawa Barat dapat menggambarkan kondisi jaringan jalan di Indonesia, dengan berbagai jenis jalan serta beragamnya kondisi setempat. Jawa Barat pun memiliki karakter tanah dasar yang cukup unik dan memerlukan penanganan tertentu.

Gambar 2.15. Jaringan jalan jawa barat

Hasil prediksi IRI setiap ruas kemudian di*plot* didalam grafik yang dapat dipahami dengan lebih mudah. Hasil model prediksi dalam bentuk tabular di*export* ke graphis. Dalam rangka untuk menunjukkan kelayakan model yang diusulkan, implementasi dan simulasi dilakukan untuk mengilustrasikan penerapan model yang telah dikembangkan untuk prediksi nilai IRI.

Data historis yang digunakan adalah data IIRMS dikumpulkan, selanjutnya dijadikan pangkalan data dalam pemodelan. Pada gambar tersebut ditunjukkan tingkat kerusakan lapisan perkerasan jalan yang berbeda. Terlihat tingkat kerusakan ada tiga kelompok, yaitu: (1) kelompok jaringan jalan dengan penurunan nilai IRI sangat cepat; (2) penurunan nilai IRI cepat; dan (3) penurunan nilai IRI lama dan penurunan nilai IRI sangat cepat. Berdasarkan pengamatan visual, kelompok pertama adalah kelompok jaringan jalan (WJ-8) yang didominasi oleh transportasi truk pasir; WJ-17, WJ-18, dan WJ-19, didominasi oleh transportasi truk batubara. Sebagai perbandingan di kelompok yang sama terdiri WJ-7 dan WJ-16 ada di kelompok tiga. Sedangkan kelompok kedua adalah jaringan jalan di pantai utara dengan beban lalu lintas tinggi.

2.7.2 Analisa Model IIRMS

IIRMS terdiri dari sistem pangkalan data sistem perencanaan, sistem program dan sistem anggaran pemeliharaan perkerasan jalan. IIRMS memiliki formula perkiraan nilai IRI seperti dapat dilihat pada persamaan berikut.

$$IRI = 0{,}98 \times e^{m.t}\{IRI_0 + 135SNCK^{-5}.NE_t + 0{,}143RDS_t + 0{,}0068Crack_t + 0{,}056PAT_t\} \ldots\ldots 2.9$$

Dimana SNCK merupakan *structural number* yang menggunakan pendekatan AASHTO, NE adalah jumlah ESAL, RDS menotasikan *rut*, PAT menunjukkan *patching*, dan t adalah usia perkerasan dalam tahun. Kualitas model perkiraan yang diperoleh dengan menerapkan model IIRMS disajikan pada gambar 2.16, nilai R^2 yang diperoleh sebesar 0.58.

Untuk mencapai tingkat akurasi prediksi yang tinggi, dalam penelitian ini dilakukan penguraian model *data-driven* melalui DM. Harapannya prosedur aplikasi yang tersedia mampu untuk "membuka" model IRI dari data terbangun. Sehingga model interpretasi yang telah ada dalam IIRMS dapat dikembangkan dengan baik.

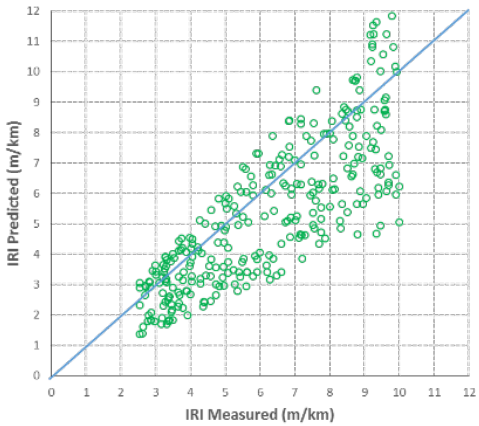

Gambar 2.16. Prediksi nilai IRI menggunakan pendekatan IIRMS

Apabila dibandingkan dengan model lain dari DM, hasil dari model DM dianggap lebih handal. Kinerja model tersebut dikonfirmasi oleh nilai R^2, MAD dan RMSE seperti dapat dilihat pada gambar 2.17. Selain untuk dapat memastikan solusi secara global yang bersifat optimal, pada tahapan ini diperlukan representasi yang diiterasi secara terintegrasi. Salah satu langkah dalam penelitian ini adalah memasukkan *subfield* yang diperluas untuk mendapatkan kecerdasan buatan dalam *machine learning* yang disediakan. *Machine learning* secara otomatis akan menyimpan catatan historis dalam memori system, yang kemudian dapat di call pada waktu yang diperlukan.

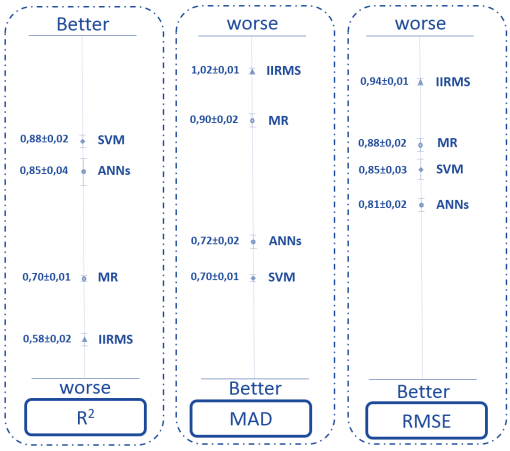

Gambar 2.17. Perbandingan tingkat akurasi model

Nilai *error matrix* dan R^2 yang dihasilkan dalam aplikasi DM dalam studi kasus ini sedikit berbeda dengan nilai yang dihasilkan saat pembangunan model keseluruhan. Namun nilai tersbut masuk dalam rentang dengan tingkat kepercayaan 95%. Dengan t-test disimpulkan bahwa model yang dibangun dengan hasil hipotetikal dalam studi kasus memiliki validasi yang baik. Pemodelan dengan pendekatan HDM-4 tidak dibahas dalam studi kasus ini karena dapat diwakili oleh persamaan IIRMS yang sudah mengadopsi sebagian kalibrasi IRI pada aplikasi dengan pendekatan HDM-4.

2.7.3 Teknik Data Mining

Dalam penelitian ini, tiga teknik DM dilatih menggunakan *dataset* yang telah dijelaskan sebelumnya untuk melakukan prediksi. Di antara tiga algoritma DM, hasil terbaik diperoleh oleh model SVM dan ANN yang memiliki penampilan yang sama. Kinerja model ini dikonfirmasi oleh nilai R^2, MAD, dan RMSE (dapat dilihat pada gambar 2.17). Semakin rendah nilai MAD dan RMSE, semakin baik model prediktif, sementara model yang sempurna harus memiliki nilai R^2 mendekati 1.0. Hasil pemodelan disajikan dengan interval kepercayaan 95% sesuai dengan distribusi t-student. Selanjutnya SVM diadopsi sebagai algoritma referensi karena memiliki tingkat akurasi yang cukup tinggi dengan jumlah iterasi yang rendah (20 iterasi).

Teknik DM atau dikenal juga dengan *association rule mining* memiliki tujuan untuk menemukan aturan assosiatif antara suatu kombinasi item. Penting tidaknya suatu aturan assosiatif dapat diketahui dengan dua parameter, *support* yaitu persentase kombinasi atribut tersebut dalam pangkalan data dan *confidence*, yaitu kuatnya hubungan antar atribut dalam aturan assosiatif. Algoritma yang digunakan dalam penelitian ini, dengan paradigma *generate and test*, yaitu pembuatan kandidat kombinasi atribut yang mungkin berdasar aturan tertentu lalu diuji. Kombinasi atribut yang memenuhi syarat tersebut disebut *frequent itemset*, yang selanjutnya digunakan untuk membuat aturan-aturan yang memenuhi syarat confidence minimum.

Dengan menganalisis gambar 2.18 (*scatterplot* nilai IRI hasil prediksi algoritma SVM dengan hasil pengukuran), dapat disimpulkan bahwa variabel yang telah ditetapkan memiliki hubungan cukup signifikan dengan nilai perubahan nilai IRI. Gambar 2.18 bagian kiri menunjukkan *scatterplots* hasil *learning* pada model SVM, sedangkan bagian kanan menggambarkan *scatterplots* hasil validasi.

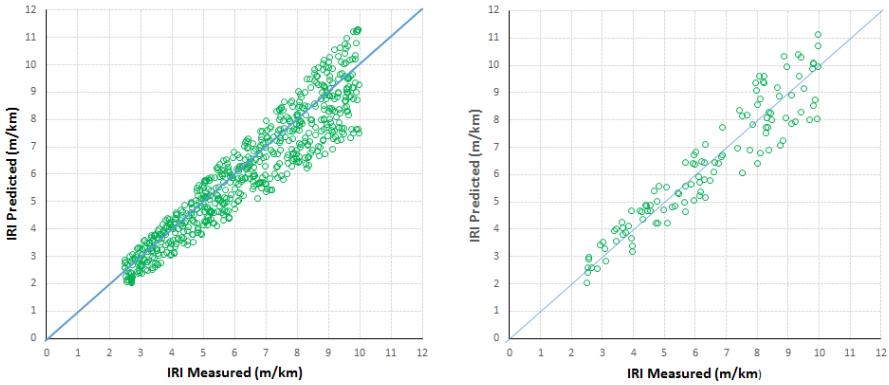

Gambar 2.18. Scatterplot pemodelan SVM

Pada tahap validasi, fitur library *rminer* digunakan untuk menggambarkan dan mendapatkan nilai kontribusi relatif dari setiap nilai masukan. Pada tahap validasi kinerja model terkonfirmasi memiliki nilai R^2, MAD dan RMSE. Berbagai operasi matematika terapan dan statistic dapat diharapkan memberikan alasa ilmiah dalam pemilihan model, namun sebagai engineer tetap memiliki pemahaman yang mencukupi untuk dapat mengambil kesimpulan dan memilih interpretasi sebagai solusi dalam penyelesaian

masalah. Tanpa pemahaman mendasar tentang ilmu perkerasan jalan, maka tools sekedar tools saja.

2.7.4 Simulasi Model Data Mining pada Jalan dengan Muatan Berlebih

Setiap jalan pada jaringan jalan dengan kode WJ memiliki karakteristik yang berbeda, dengan faktor beban yang berbeda. Selanjutnya, masing-masing kelompok dari hasil pemodelan dibandingkan dengan hasil pengukuran dari data jembatan timbang di segmen tersebut. Jika jaringan dipisahkan menjadi empat kategori jalan dengan muatan berlebih, maka hasil pengukuran dengan persentase muatan berlebih tertinggi adalah kelompok 1, yang ditandai oleh muatan berlebih sebesar 38%, selanjutnya disebut *heavy overload*. Kelompok 2, yang selanjutnya disebut *medium overload*, dengan muatan berlebih mencapai 30%. Sementara kelompok 3, yang merupakan poros utama di koridor pantai utara menyumbang sebanyak 29% *overload*, Segmen yang tersisa dari jaringan jalan nasional dengan rata-rata muatan berlebih sebesar 17%. Perbedaan jenis jalan dengan muatan berlebih menghasilkan pola penurunan kinerja perkerasan berbeda.

Hasil simulasi menunjukkan bahwa perbedaan faktor beban dapat mengubah umur layan perkerasan jalan. Penurunan umur layan jalan merupakan dampak dari kerusakan dini akibat jalan dibebani dengan muatan berlebih. Kerusakan tidak hanya terjadi pada permukaan jalan, namun sampai dengan struktur jalan. Perubahan nilai IRI di ruas jalan dengan muatan berlebih mencapai lebih besar dari 4 m/km pada tahun kedua. Dengan demikian, dapat dipahami bahwa dalam satu tahun tingkat jalan layan telah melewati batas normal. Sedangkan jalan dengan pembebanan normal, bisa bertahan lebih lama. Diperlukan waktu selama 5 tahun untuk mencapai pengurangan IRI hingga mencapai lebih dari 4 m/km.

2.7.5 Implementasi Optimasi GA

Pendekatan *Pareto solution* digunakan untuk menentukan model optimasi berbasis GA. Solusi tersebut disusun untuk menghasilkan optimasi nilai IRI dan besaran biaya pemeliharaan. Hasil optimasi yang digunakan sebagai dasar pengambilan keputusan selanjutnya digunakan sebagai solusi akhir dan diilustrasikan pada penerapan model. Jaringan jalan yang sama dengan gambar 2.15 digunakan sebagai ruas simulasi. Program pemeliharaan yang optimal dipilih dengan menggunakan *Pareto approach solution*. Pendekatan *Pareto optimality* digunakan untuk menentukan generation (gambar 2.19 bagian kiri).

Dalam tahapan optimasi ini, skenario pemeliharaan dilakukan dengan iterasi memanfaatkan *tools* yang disediakan oleh R-*tools* dengan melakukan *simulation generation* berjenjang. Skenario pemeliharaan dilakukan bertahap secara berurut kemudian dikombinasikan untuk mencapai titik optimum yaitu yang disebut *Pareto optimality.* Pola optimasi dengan pendekatan *Pareto* dilakukan dengan melakukan transformasi dengan *first generation*. Hal ini sesuai dengan Teori Pareto, bahwa

sebagian kecil (20%) dari faktor penyebab permasalahan memberikan potensi penyelesaian sebagian besar (80%) masalah. Dalam melakukan optimasi pemeliharaan jalan, dikenal indikator yaitu nilai IRI. Diharapkan dengan memilih skenario pemeliharaan yang yang menjadi kelompok indeks berbasis *Pareto*, maka pola biaya pemeliharaan mampu membaca pergerakan nilai IRI secara keseluruhan. Hasil *first generation* pendekatan parto dapat dilihat pada gambar 2.19 bagian kanan.

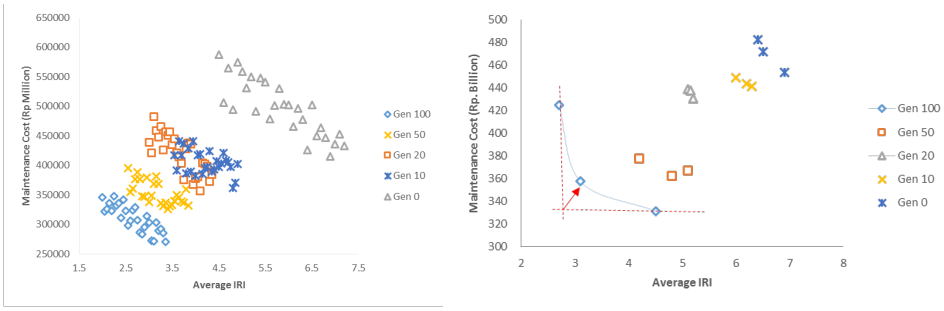

Gambar 2.19. *Pareto approach*

Untuk menyederhanakan skenario optimasi dalam penelitian ini dilakukan pendekatan kondisi jalan dengan muatan berlebih dengan 4 jenis pembebanan jalan nasional. Pemeliharaan dipilih dengan mencapai IRI terendah dan menggunakan anggaran tersedia. Dengan pendekatan *Pareto* yang disediakan oleh NSGA-II pada R, didapatkan tipe pemeliharaan tiap tahun serta prediksi nilai IRI yang diprediksi pada ruas-ruas tiap kelompok pembebanan. Perkiraan nilai IRI yang didapatkan dalam 6 tahun sebelum dan sesudah optimasi dapat dilihat pada gambar 2.20. Simulasi dilakukan dengan melakukan iterasi sesuai dengan diagram alir di gambar 2.11 bagian *genetic algorithm*, yang secara dinamis terhubung dengan bagian model prediksi kinerja jalan melalui iterasi model SVM. Kedua bagian utama tersebut saling dihubungkan dan dikontrol dengan *subject* persamaan (2.4), (2.5), dan (2.6). Nilai IRI yang menjadi target dalam simulasi tersebut adalah nilai rata-rata IRI jaringan jalan paling optimal dengan memperhatikan batas minimal nilai IRI pada setiap ruas. Iterasi model menunjukan bahwa diperlukan langkah *jump* untuk mencapainya.

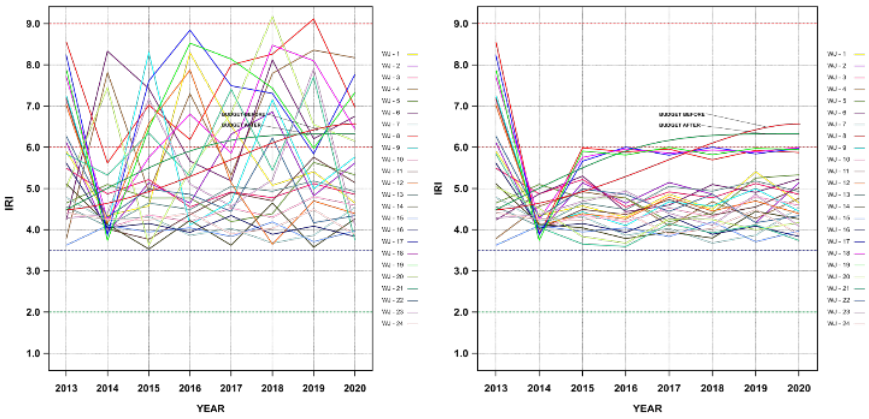

Gambar 2.20. Prediksi IRI sebelum dan sesudah optimasi

Pencapain IRI yang telah diperkirakan tersebut di atas berdasarkan skenario terpilih dengan rentang IRI yang telah ditentukan terlebih dahulu. Namun karena anggaran yang terbatas, optimasi ini sekaligus memberikan pilihan prioritas. Di tahun awal optimasi dilakukan dengan pilihan prioritas terhadap kelompok ruas dengan berbagai jenis pembebanan jalan dilakukan rekonstrusksi secara bertahap untuk dapat menjaga nilai maksimal anggaran tersedia. Setelah semua kelompok dilakukan rekonstruksi selanjutnya diberikan pilihan jenis pemeliharaan sampai tahun ke-15. Secara lengkap skenario tipe pemeliharaan hasil optimasi yang dihasilkan dapat dilihat pada gambar 2.21.

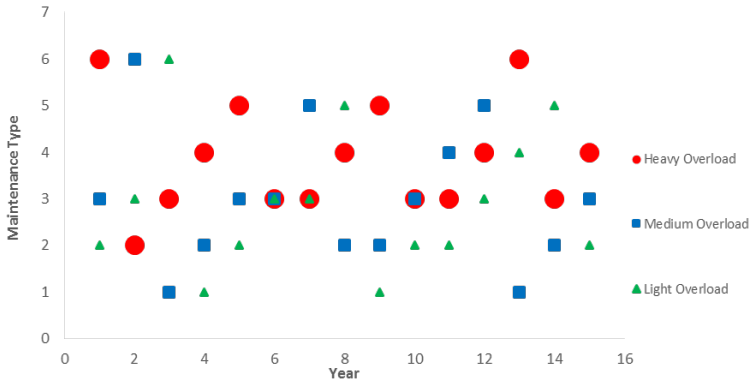

Gambar 2.21. Skenario tipe pemeliharaan

Skenario pemeliharaan bersifat dinamis dan terus menyesuaikan dengan kondisi nyata di lapangan. Kegiatan pemeliharaan tidak bisa dimulai dari tengah tanpa melalui kajian awal terlebih dahulu. Tindakan pemeliharaan yang sekedar menyelesaikan masalah sesaat tidak dapat mampu meningkatkan kinerja jalan secara utuh. Diperlukan strategi pemeliharaan yang terstruktur dengan berbagai skenario pilihan. Sehingga saat satu skenario tidak bisa dijalankan, ada skenario lain yang bisa dikembangkan. Selanjutnya untuk dapat meyakinkan para *stakeholder* agar memperhatikan efektifitas pemeliharaan berbasis pemisahahan kelompok pembebanan dapat dilihat pada gambar 2.22.

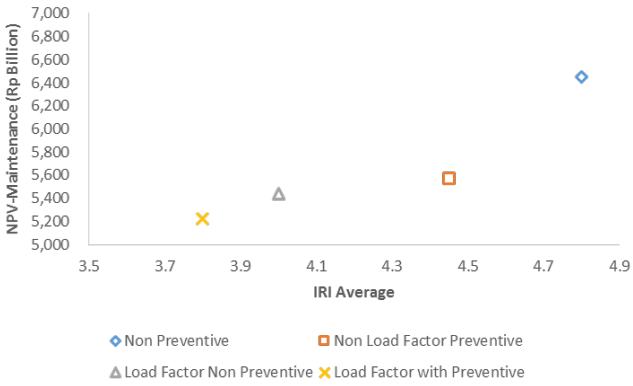

Gambar 2.22. Nilai manfaat

Hasil tersebut didapatkan dari simulasi pemeliharaan jangka panjang dengan skenario pemisahan pembebanan dan tanpa pemisahan jenis pembebanan, serta melibatkan optimasi *preventive maintenance* dan *non-preventive*. Pengukuran dilakukan dengan simulasi 15 tahun menggunakan pendekatan *net present value*.

2.8 Kesimpulan

1. Pengembangan model dilakukan sebanyak 3 tahap, yaitu pengembangan model prediksi kinerja jalan, model optimasi pemeliharaan jalan, dan terakhir model DSS. Model prediksi kinerja jalan dikembangkan dengan melakukan pendekatan dan pendalaman DM. selanjutnya GA dimanfatkan untuk menyelesaikan MOO dalam tahapan optimasi, dan terakhir pendekatan GIS digunakan untuk menyusun aplikasi *interface* bagi para pemegang kebijakan sebagai penyederhanaan dari konsep DSS yang dikembangkan.
2. Pengembangan model dengan pendekatan DM dimulai dengan menggunakan data awal pada tahapan *learning*, kemudian masuk tahapan *test* dan terakhir tahapan validasi.
   a. Teknik DM, terutama algoritma SVM dan ANN terbukti menjadi alat yang kuat untuk memprediksi dan menginterpretasi nilai IRI. Pendekatan ini mampu menjalankan tahapan *learning* dengan akurasi yang tinggi dan mampu menggambarkan hubungan yang kompleks antara perubahan nilai IRI dan *distress* serta kondisi lalu lintas sebagai faktor yang berkontribusi. Pada tahapan ini SVM mencapai kinerja yang tinggi dengan R^2 mencapai 0.91 sebagai indikator kinerja serta nilai error didapatkan MAD 0.53 dan RMSE 0.71.
   b. Berdasarkan algoritma GSA, ditunjukan bahwa kontribusi terbesar adalah ESAL. Hal ini membuktikan bahwa perubahan nilai IRI sangat dipengaruhi oleh beban kendaraan yang melintasi perkesaran jalan dengan kontribusi sebesar 26.30%. Proses penurunan nilai IRI konsisten terhadap waktu dan memiliki hubungan erat dengan IRI awal. Seluruh distress memiliki hubungan satu sama lain, terutama proses *crack, pothole* dan *patching*.
   c. Berdasarkan VEC, pendekatan DM berupa algoritma MR, ANN, dan SVM, masing masing memiliki tingkat akurasi berbeda. Akurasi tertinggi tercapai pada SVM dengan 20 *runs performed*, *hyperparameters* terbaik untuk mencapai model SVM yang fit adalah menggunakan $\epsilon = 0.07 \pm 0.01$ dan $\gamma = 0.05 \pm 0.00$. Sedangkan *hyperparameters* untuk ANN adalah $H = 3 \pm 1$.
   d. DM memiliki kemampuan *learning* dan fleksibilitas yang tinggi, bahkan ketika menyelesaikan masalah berdimensi tinggi. Dukungan pangkalan data yang terstruktur dengan data yang signifikan dapat memperkuat kinerja DM. Namun, di sisi lain kelemahan utama yang terkait dengan penerapan teknik DM dalam memecahkan masalah yang kompleks adalah model interpretasi berbentuk bahasa matematika tingkat tinggi sesuai dengan algoritma yang diimplementasikan. Untuk mengatasi kelemahan tersebut, dalam penelitian ini diterapkan pendekatan GSA selama proses *learning, test,* dan *validasi*.

3. Pengembangan model optimasi pemeliharaan perkerasan jalan dimulai dengan melakukan identifikasi *objective* dan *constraint* terhadap permasalahan pemeliharaan perkerasan jalan dengan muatan berlebih.
   a. Dalam pemeliharaan perkerasan jalan, terdapat beberapa *objective* dan *constraint* yang harus diselesaikan secara bersamaan. Model MOO dengan pendekatan GA dipilih sebagai model optimasi yang tepat untuk melakukan optimasi sistem manajemen pemeliharan jalan.
   b. Pendekatan *Pareto optimization* merupakan langkah awal untuk menentukan jumlah kromosom dan jumlah *running* yang diperlukan dalam proses optimasi ini. Untuk mencapai model optimasi yang baik, tahapan optimasi dilakukan pendekatan SOP terlebih dahulu untuk melihat setiap *objective* dan masing-masing *constraint*.
   c. Hasil uji model dengan strategi pemeliharaan standar, yang ditunjukan dengan kurva REC memperlihatkan bahwa pendekatan MOO mendekati akurasi terbaik.
4. Konsep DSS dengan aplikasi QGis yang dikembangkan mampu menampilkan aplikasi *interface* yang sederhana dan mampu memberikan pemahaman kepada para *stake holder* untuk melaksanakan sistem manajemen perkerasan jalan dengan langkah sederhana dan menyeluruh. Konsep *interface* cukup sederhana dan fleksibel dapat dikembangkan kembali sesuai dengan kebutuhan lokal.
5. Berdasarkan uji hipotetikal melalui implementasi model prediksi, dihasilkan bahwa analisis IIRMS cukup sederhana dan menunjukkan kapasitas prediksi yang baik, namun membutuhkan analisis yang lebih rinci dan masih memiliki keterbatasan akurasi ($R^2 \leq 0.7$). Dengan menggunakan teknik DM melalui pendekatan algoritma SVM, model prediksi memiliki kapasitas yang sangat baik untuk melakukan interpretasi terhadap data yang besar. Implementasi model juga dapat melakukan memprediksi tingkat kinerja jalan dengan beberapa faktor beban muatan kendaraan yang berbeda. Teknik DM (MR, ANNs, dan SVM) yang diimplementasikan memiliki hubungan yang kuat ($R^2 \geq 0.7$). Model ini dapat digunakan dalam sistem manajemen perkerasan jalan dengan beberapa kondisi pembebanan yang berbeda.
6. Berdasarkan uji hipotetikal melalui implementasi model optimasi, dihasilkan bahwa optimasi MOO dengan pendekatan P*areto optimality* dengan generate 0, 10, 20, 50, dan 100 memberikan pilihan optimasi yang cukup baik. Model dapat menyusun pilihan skenario pemeliharaan, dan hasilnya pemeliharaan dengan memperhatikan kelompok jalan dengan muatan berlebih dan metode pemeliharaan preventif memberikan nilai manfaat tertinggi.
7. Dengan melakukan pendekatan yang cukup kompleks, melalui pemanfaatan berbagai algoritma dalam DM dan model lainnya. Selanjutnya dapat dikembangkan lebih banyak solusi inovatif untuk menyelesaikan berbagai permasalahan, terutama dalam sistem sistem manajemen perkerasan jalan. Berikut beberapa hal sebagai saran untuk penelitian lanjutan:
   a. Penelitian ini terbatas pada struktur perkerasan lentur. Untuk perkerasan kaku yang memiliki karakteristik dan perilaku berbeda dapat dilakukan pendekatan yang sama dengan merubah pola pendekatan variabel dan algoritma.

b. Kemampuan DM yang dimiliki *package rminer* cukup tinggi dan luas. Berbagai model prediksi dan keperluan interpretasi dapat dikembangkan dengan pendekatan DM. Pendalaman pemahaman bahasa komputer dan algoritma matematika sangat diperlukan untuk mendapatkan hasil penelitian yang lebih dalam.
c. Sebagaimana dimaksud seluruh deskripsi pengembangan sistem, integrasi penuh dari semua teknologi dan alat akan meningkatkan kemampuan dan *user-friendly*. Dalam penelitian ini, integrasi teknologi sistem informasi geografis baru pada tahapan konsep dan simulasi tingkat awal, kebutuhan pada versi penelitian berikutnya berupa kemampuan migrasi dan perluasan sistem terhadap berbagai model sangat menarik untuk dikembangkan.
d. Mendalami lebih banyak pengetahuan tentang parameter optimasi untuk menghasilkan *output* terbaik hasil algoritma genetik, serta melanjutkan eksplorasi MOO, seperti SPEA-2 atau SMSEMOA.
e. Terakhir, aplikasi dan validasi sistem terbangun disarankan untuk dilakukan secara *real time.* Diharapkan dapat memberikan wawasan penting mengenai perkembangan fungsi baru dan perbaikan yang ada

2.9 Daftar Pustaka

Abaza, K. (2006). Iteraive Linear Approach for Nonlinear Nonhomogenous Stochastic Pavement Management Models. Journal of Transportation Engineering Vol 132 No. 3, 244-256.

Abaza, K., & Ashur, S. (1999). Optimum Decision Policy for Management of Pavement Maintenance and Rehabilition. Journal of Transportation Research Board No. 1655, 8-15.

Abaza, K., & Murad, M. (2007). Dynamic Probabilistic Approach for Long-Term Pavement Restoration Program with Added User Cost. Journal of Transportation Research Board No. 1990, 48-56.

Abaza, K., Ashur, S., & Rabay'a, A. (2001). A Macroscopic Optimization System for the Management of Pavement Rehabilition. Proceedings of The 20th Australian Road Researh Board (ARRB) Conference. Melbourne, Australia 19-21 March.

Abaza, K., Murad, M., & Al-Khatib, I. (2004). Integrated Pavement wih a Markovian Prediction Model. Journal of Transportation ENgineering Vol 130, No.1, 24-33.

Akofio-Sowah, M. A., & Kennedy, A. A. (2014). A Critical Review of Performance-Based Transportation Asset Management in United States Transportation Policy. Proceedings of the 17th IRF World Meeting & Exhibition. International Road Federation.

Bai, Q., & Labi, S. (2009). Uncertainty-based tradeoff analysis methodology for integrated transportation investment decision-making. USDOT Region V RegionalUniversity Transportation Center Final Report (NEXTRANS Project No 020PY01).

Bakko, A. I., & Horvath, Z. (2011). Decision Supporting Model for Highway Maintenance. Journal of Computing in Civil Engineering.

Beg, M. A., & Banerjee, A. (2015). Developing Optimized Maintenance Work Programs for an Urban Roadway Network using Pavement Management System. 9th International Conference on Managing Pavement Assets.

Benjamin, C. (1985). A Linear Gola Programming Model for Public Sector Project Selection. Journal of the Operational Research Society 36 (1), 13-24.

Chan, W., Fwa, T., & Tan, C. (1994). Road Maintenance Planning using Genetic Algortihms I:Formulation. Journal of Transportation Engineering, Vol 120 No. 5, 693-709.

Chikezie, C., Abejide, S., & Kolo, A. (2011). Review of application of genetic algorithms in optimization of flexible pavement maintenance and rehabilitation in Nigeria. World J. Eng. Pure Appl. Sci. 3, 68-76.

Cook, W. (1984). Goal Programming and Financial Planning Models for Highway Rehabilition. Journal of the Operational Research Society, 34 , 3, 217-223.

Cortez, P. (2010). Data mining with neural networks and support vector machines using the r/rminer tool. Advances in Data Mining: Applications and Theoretical Aspects, 10th Industrial Conference on Data Mining, 83,. Berlin, Germany: J In P. Pemer, editor,.

Coutinho-Rodrigues, J., Simão, A., & Antunes, C. H. (2011). A GIS-based multicriteria spatial decision support system for planning urban infrastructures. Decision Support Systems, 51(3), 720-726.

D'Andrea, A., Cappadona, C., La Rosa, G., & Pallegrino, O. (2014). A functional road classification with data mining techniques. Journal of Transport 29.4 , 419-430.

Di Mino, G., De Blasiis, M. R., Di Noto, F., & Noto, S. (2013). An Advanced Pavement Management System based on a Genetic Algorithm for a Motorway Network. Proceedings of the Third International Conference on Soft Computing Technology in Civil, Structural and Environmental Engineering (p. 26). Stirlingshire, Scotland. : Civil-Comp Press.

Ding, T., Sun, L., & Chen, J. (2013). Optimal Strategy of Pavement Preventive Maintenance Considering Life-Cycle Cost Analysis. Social and Behavioral Sciences 96, 1679 – 1685.

Ede, A. N. (2014). Cumulative Damage Effects of Truck Overloads on Nigerian Road Pavement. International Journal of Civil & Environmental Engineering IJCEE-IJENS Vol: 14 No: 01, 21-26.

Elhadidy, A. A., Elbeltagi, E. E., & Ammar, A. M. (2015). Optimum analysis of pavement maintenance using multi-objective genetic algorithms,. HBRC Journal (2015) 11, 107-113.

Ertel, W. (2009). Introduction to Artificial Intelligence. Springer, ISBN 9780857292988.

Fedra, K., & Reitsma, R. (1990). Decision Support and Geographical Information Systems. Dordrecht, The Netherlands: Kluwer Academic Publishers.

Feighan, K., Shahin, M., & Sinha, K. (1987). A Dynamic Programming Approach to Optimization for Pavement Management System. 2nd North Am. Conf on Managing Pavement (pp. 2.195-2.206). Ontario Ministry of Transportation and Communications and US Federal Highway Administration.

Ferreira, A., Antunes, A., & Picados-Santos, L. (2002). Probabilistuc Segment-Linked Pavement Management Optimization Model. Journal of Transportation Engineering, Vol 128 No. 6, 568-577.

Fu, T. C. (2011). A review on time series data mining. Engineering Applications of Artificial Intelligence, 24(1), , 164-181.

Fwa, T. F., Tan, C., & Chan, W. (1994). Road Maintenance Planning Using Genentic Algorithms. II: Analysis. Journal of Transportation Engineering Vol. 120 No. 5, 710-722.

Fwa, T., & Shinha, K. (1988). Highway Routine Maintenance Programming at Network Level. Journal of Transportation Engineering Vol 114 No. 5.

Fwa, T., Chan, W., & Hoque, K. (2000). Multiobjective Optimization for Pavement Maintenance Programming. Journal of Transportation Engineering, ASCE Vol 119 No. 3, 419-432.

Fwa, T., Chan, W., & Tan, C. (1996). Genetic Algorithms Programming of Road Maintenance and Rehabilition. Journal of Transportation Engineering, ASCE, Vol 122, No. 3, 246-253.

Gao, L., Xie, C., Zhang, Z., & Waller, S. (2012). Network-level road pavement maintenance and rehabilitation scheduling for optimal performance improvement and budget utilization. Comput.-Aided Civ. Infrastruct. Eng. 27, 278-287.

Garcia-Diaz, A., & Liebman, J. (1980). An Investment Staging Model for a Bridge Replacement Problem. Operations Research Vol 28, No. 3 Part II, 736-753.

Gendreau, M., & and Duclos, L. (1989). A Decision-Support System Approach for Pavement Management Planning. the 15th World Conference on Transport Research. Japan.

Gluch, P., & Baumann, H. (2004). The life cycle costing (LCC) approach: a conceptual discussion of its usefulness for environmental decision-making. " Building and Environment39 (5), 571-580.

Haas, R., Hudson, W. R., & Zniewski, J. (1994). Modern Pavement Management. Florida: Krieger Publishing Company, Malabar.

Hadiwardoyo, S.P., Sumabrata, R., & Berawi, M. (2012). Tolerance Limit for Trucks With Excess Load In Transport Regulation In Indonesia. Makara Journal of Technology, Volume 16 No.1, 85-92.

Harper, W., & Majidzadeh, K. (1991). Use of Expert Opinion in Two Pavement Management System. Journal of Transportation Research Board, No. 1311, 242-247.

Hass, R. (2003). Good Technical Foundations Are Essential for Successful Pavement Management. Maintenance and Rehabilitation of Pavements and Technology Control (pp. 3-28). Guimaraes: Universidade do Minho-Escola de Engenharia.

Hill, I., Cheetham, A., & Hass, R. (1991). Development and Immplementation of a Pavement Management System fo Minnesota. Transportation Research Noard No. 1311, 22-41.

Kang, M.-W., Jha, M. K., & Schonfeld, P. (2012). Applicability of highway alignment optimization models. Transportation Research, 257-286.

Karan, M., & Haas, R. (1976). Determining Investment Priorities for Urbana Pavement Improvements. Journal of Aasociation of Asphalt Paving Technology Vol 45.

Karlaftis, A., & Badr, A. (2015). Predicting asphalt pavement crack initiation following rehabilitation treatments. Transportation Research Part C 55, 510–517 .

Lemis-Petropoulos, P. A., Chassiakos, A. P., & Theodorakopoulos, D. D. (2012). An Expert System for Pavement Management in Urban Road Networks.

Li, N. H., & Huot, M. (1998). Integer Programming of Maintenance and Rehabilition Treatments for Pavement Networks. Transportaion Research Board No. 1629, 242-248.

Liao, S., Chu, P., & Hsiao, P. (2012). Data mining techniques and applications – A decade review from 2000 to 2011. Expert Systems with Applications 39, 11303–11311.

Liu, H., Motoda, H., Setiono, R., & Zhao, Z. (2010). Feature Selection: An Ever Evolving Frontier in Data Mining. Proceedings of the Fourth Workshop on Feature Selection in Data Miing, (pp. 4-13). Hyderabad, India.

Lytton, R. (1985). From Rangking to True Optimization. In the Proceeding of North American Pavement Management Conference (pp. 5.3 - 5.28). Ontario Ministry of Transportation and Communicaion and US Federal Highway Administration.

Mahoney, J., Ahmed, N., & Lytton, R. (1978). Optimization of Pavement Rehabilition and Maintenance by Use of Integer Programming. Transportation Research Board No. 674, 15-22.

Martinaz Diaz, M., & Perez, I. (2015). Mechanistic-empirical pavement design guide: features and distinctive elements. Journal of Construction, 32-40.

Marzouk, M., Awad, E., & El-said, M. (2012). An integrated tool for optimizing rehabilitation programs of highways pavement,. Baltic J. Road Bridge Eng. 7, 297-304.

Moazami, D., Muniandy, R., Hamid, H., & Md. Yusoff, Z. (2011). The use of analytical hierarchy process in priority rating of pavement maintenance. Scientific Research and Essays, 2447-2456.

Morcous, G., & Lounis, Z. (2005). Maintenance optimization of infrastructure networks using genetic algorithms. Automation in Construction 14 , 129– 142.

Pais, J., Amorim, S., & Minhoto, M. (2013). Impact of Traffic Overload on Road Pavement Performance. J. Transp. Eng., ASCE, 139(9), , 873–879.

Parente, M., Correia, A. G., & Cortez, P. (2014). Artificial Neural Networks Applied to an Earthwork Construction Database. In: Toll D, Zhu H, Osman A, et al (eds) Second Int.Conf. Inf. Technol. Geo-Engineering. IOS Press, Durham, UK, 200–205 .

Pilson, C., Hudson, W., & Anderson, V. (1999). Multiobjective Optimization in Pavement Management by Using Genetic Algorithms and Efficient Surfaces. Journal of The Transportation Research Board No. 1655, 42-48.

Rahman, F. A., Desa, M. I., Wibowo, A., & Haris, N. A. (2014). Knowledge Discovery Database (KDD)-Data Mining Application in Transportation. Proceeding of the Electrical Engineering Computer Science and Informatics, 1(1), , (pp. 116-119.).

Rahman, S., & Vanier, D. J. (2004). Life cycle cost analysis as a decision support tool for managing municipal infrastructure. Toronto, Ontario,.

Rifai, A.I., Hadiwardoyo, S.P., Correia, G.A., Pereira, P., & Cortez, P. (2015b). Implementasi Data Mining Untuk Mendukung Sistem Manajemen Perkerasan Jalan Di Indonesia. Jurnal HPJI Vol. 1 No. 2, 93-104.

Rifai, A.I, Hadiwardoyo, S.P., Correia, G.A., & Pereira, P. (2015). A Conceptual Model Decision Support System for Maintenance Optimization of Overload Highway Pavements under Financial Constraints. Quailty In Research. Lombok, Indonesia.

Rouhani, S., Ghazanfari, M., & Jafari, M. (2012). Evaluation model of business intelligence for enterprise systems using fuzzy TOPSIS. Expert Systems with Applications, 39(3), 3764-3771.

Saha, P., & Ksaibati, K. (2015). A risk-based optimisation methodology for pavement management system of county roads. . International Journal of Pavement Engineering, 1-11.

Santos, J., & Ferreira, A. (2012). Pavement design optimization considering costs and M&R interventions. Social and Behavioral Sciences 53 , 1184 – 1193.

Sayers, M., & Karamihas, S. (1995). The little book of profiling, UMTRI, In:Sayers W, editor. On the calculation of IRI from longitudinal road profile.

Shahin, M. (1994). Pavement Management for Airports, Roads and Parking Lots-,. New York: Chapman & Hall.

Sianipar, C. P., & Dowaki, K. (2014). Eco-burden in pavement maintenance: Effects from excess traffic growth and overload. Sustainable Cities and Society 12, 31–45.

Tack, J., & Chou, E. (2002). Multiyear Pavement Repair Scheduling Optimization by Preconstrained Genetic Algorithm. Journal of Transportation Research Board No. 1816, 3-9.

Terzi, S. (2006). Modeling the Pavement Present Serviceability Index of Flexible Highway Pavements Using Data Mining. Journal of Applied Sciences, 193-197.

Tinoco, J., Correia, A. G., & Cortez, P. (2014). Support vector machines applied to uniaxial compressive strength prediction of jet grouting columns. Computers and Geotechnics 55 hal. 132–140, 132-140.

Tinoco, J., Correia, A. G., & Cortez, P. (2014). Support vector machines applied to uniaxial compressive strength prediction of jet grouting columns. Computers and Geotechnics 55, 132–140.

Tinoco, J., Correia, A., & Cortez, P. (2011). Application of data mining techniques in the estimation of the uniaxial comprehensive strength of jet grouting columns over time, C. onstruction and Building Material 25, 1257-1262.

Varela-González, M., Solla, M., Martínez-Sánchez, J., & Arias, P. (2014). A semi-automatic processing and visualisation tool for ground-penetrating radar pavement thickness data. Automation in Construction 45, 42-49.

Wang, F., Zhang, Z., & Machemehl, R. B. (2003). Decision Making Problem for Managing Pavement Maintenance and Rehabilitation Projects. 82nd TRB Meeting, (pp. 1-10). Washington D.C.,.

Wang, X. Z. (2012). Data mining and knowledge discovery for process monitoring and control. Springer Science & Business Media.

Yuhong Wang, P., Wen, Y., Zhao, K., Chong, D., & Wong, A. S. (2014). Evolution and locational variation of asphalt binder aging in long-life hot-mix asphalt pavements. Construction and Building Materials 68 , 172–182.

Zhang, Z., & Murphy, M. R. (2013). A Web-Based Pavement Performance and Maintenance Management and GIS Mapping System for Easy Access to Pavement Condition Information: Final Report (No. 5-9035-01-P1-Final).

Zhou, G., Wang, L., Wang, D., & Reichle, S. (2010). Integration of GIS and Data Mining Technology to Enhance the Pavement Management Decision Making. Journal of Transportation Engineering, 332-341

Dr. Andri IRFAN

Pria kelahiran Majalengka penggemar kopi ini lebih sering dipanggil Kang Irfan oleh rekan sejawatnya di Direktorat Jenderal Bina Marga. Aktifitas akademisnya, selain menjadi dosen teknik sipil, Kang Irfan juga merupakan *reviewer* jurnal ketekniksipilan, serta peneliti bidang perkerasan jalan, *data mining* dan *artificial intelligence*. Sebelum menyelesaikan jenjang pendidikan doktor bidang perkerasan jalan di Universitas Indonesia dan Universidade do Minho Portugal melalui beasiswa LPDP, Kang Irfan melakukan penelitian bersama di ALGORITMI Research Centre dan di The Centre for Territory, Environment and Construction (CTAC) University of Minho dengan Pendanaan Direktorat Jenderal Pendidikan Tinggi dan dukungan Kedubes RI di Lisboa. Berbagai hasil penelitian dengan pendekatan *decision support systems, data mining,* dan *data science and forecasting* telah dipublikasikan di jurnal nasional maupun internasional.