

IMPLEMENTASI *DATA MINING* UNTUK MENDUKUNG SISTEM MANAJEMEN PERKERASAN JALAN DI INDONESIA

A. Irfan Rifai

Satuan Kerja Pelaksanaan Jalan
Bebas Hambatan Tanjung Priok,
Balai Besar Pelaksanaan Jalan
Nasional IV Jakarta
andrifan@yahoo.com

Sigit P. Hadiwardoyo

Departemen Teknik Sipil,
Fakultas Teknik,
Universitas Indonesia,
Depok 16424
sigit@eng.ui.ac.id

A. Gomes Correia

Centre Algoritmi,
School of Engineering,
University of Minho Portuga
agc@civil.uminho.ptl

Paulo Pereira

Centre Algoritmi,
School of Engineering,
University of Minho Portuga
agc@civil.uminho.ptl

Paulo Cortez

Centre Algoritmi,
School of Engineering,
University of Minho Portuga
agc@civil.uminho.ptl

Abstract

The use of service level indicators of road surface by using the International Roughness Index (IRI) has been widely used in many countries including Indonesia. Pavement Management System was developed in Indonesia by using the data IRI. The increasing of roads network and limitations of the tool to measure the road surface (roughness meters), so the number of the recording can not fully recorded. But recording the performance data of the road network has been widely performed manually. This data has been collected in a basis data so that these can be used to create a model for IRI through data mining approaches. The extraction of data from the national road network to the region of West Java is used as a case study in the study. IRI data mining models have been developed in this study with the approach of Artificial Neural Network and Support Vector Machines. The results of the IRI model development approach is validated by the level of 90 %. The success of the development of this model can be used to use the existing data to support the management of the road network with the Pavement Management System.

Keywords: road surface, pavement management, data mining, IRI model

Abstrak

Penggunaan indikator tingkat layanan permukaan jalan dengan *International Roughness Index* (IRI) sudah banyak digunakan di berbagai negara termasuk di Indonesia. Bahkan Sistem Manajemen Perkerasan di Indonesia dikembangkan dengan menggunakan data IRI. Namun luasnya jaringan jalan dan keterbatasan alat ukur untuk menilai kerataan permukaan jalan menyebabkan pencatatan tingkat layanan jalan masih belum menyeluruh. Meskipun demikian data kinerja jaringan jalan yang dilakukan secara manual telah banyak dilakukan. Hasil pencatatan data yang lengkap ini sudah berbentuk basis data yang diharapkan dapat dimanfaatkan untuk menyusun model IRI melalui pendekatan *data mining*. Model IRI dengan data mining yang dikembangkan pada studi ini menggunakan pendekatan *Artificial Neural Network dan Support Vector Machines*. Hasil pengembangan model IRI ini divalidasi dengan tingkat kesesuaian 90 %. Hasil pengembangan model ini dapat digunakan untuk memanfaatkan data yang ada untuk mendukung pengelolaan jaringan jalan dengan Sistem Manajemen Perkerasan.

Kata-kata kunci: permukaan jalan, manajemen perkerasan, *data mining*, model IRI

PENDAHULUAN

Sejak tahun 1990-an Indonesia telah mengembangkan sistem manajemen perkerasan secara modern dengan nama *Integrated Indonesian Road Management System*

(IIRMS). Seiring dengan perkembangan teknologi dan semakin luasnya ruang lingkup kebutuhan sistem manajemen perkerasan jalan, IIRMS perlu dikembangkan lebih lanjut untuk pencapaian yang lebih optimal (Tranggono, 2013). Hal tersebut didorong oleh meningkatnya pembangunan infrastruktur di Indonesia, seperti halnya pemerintah di negara-negara berkembang yang masih terus membangun infrastruktur transportasi untuk memenuhi kebutuhan yang ada meskipun dengan kendala terbatasnya anggaran (Lee, 2014). Dengan keterbatasan anggaran tersebut pemerintah harus tetap mampu membangun dan meningkatkan infrastruktur transportasi tanpa mengesampingkan pemeliharaan yang baik pada seluruh jaringan jalan yang telah terbangun.

Salah satu faktor penentu keberhasilan dalam sistem manajemen perkerasan adalah akurasi model perkiraan tingkat layanan jalan, sehingga dapat memberikan dukungan informasi bagi penyedia infrastruktur jalan untuk menentukan kebijakan dan strategi pemeliharaan. Seperti halnya disampaikan oleh Zouch (2012) bahwa model perkiraan kondisi perkerasan jalan merupakan komponen terpenting dalam sistem manajemen perkerasan jalan. Tingkat kerusakan jalan dapat terjadi pada lapis fondasi jalan, lapis permukaan, atau keduanya secara bersamaan. Namun untuk melakukan model perkiraan yang tepat dapat dimulai dengan memeriksa dan mencatatkan kondisi permukaan jalan melalui berbagai ukuran tingkat layanan yang biasa digunakan dalam standar. Salah satu cara dalam menggunakan standar tingkat kerataan yang sudah banyak digunakan adalah International Roughness Index (IRI), yang merupakan salah satu indeks yang paling banyak digunakan di dunia internasional (Kropac, 2005).

Berbagai jenis penyebab kerusakan jalan harus dilakukan dengan cara didata dan dicatat secara terstruktur dengan jelas sehingga dapat dimanfaatkan sebagai data rujukan yang tepat. Dengan pendataan dan pemisahan yang teratur, *basis data* yang terbangun dapat digunakan untuk mendukung para pemangku kepentingan melakukan pemeliharaan yang tepat untuk setiap ruas jalan dengan kondisi yang berbeda (Zhou, 2012). Secara bersamaan pengumpulan informasi kondisi permukaan jalan, yang kemudian menjadi *basis data*, harus dapat dipastikan merupakan kelompok data yang dapat diformulasikan menjadi sebuah rujukan bagi pengambil keputusan melalui optimasi pendekatan matematika (Lamprey, 2008). Selanjutnya, *basis data* tersebut harus dapat dimanfaatkan dan memiliki arti. Metode memanfaatkan dan usaha melakukan interpretasi terhadap *basis data* semakin berkembang, salah satunya dengan model data mining. Melalui pendekatan pemodelan baru dalam *Data Mining* (DM), kumpulan data tersebut akan mampu menjelaskan prediksi kondisi permukaan jalan. Selanjutnya melalui berbagai model yang sedang dikembangkan untuk menyusun model perkiraan, sebagaimana yang berkembang dalam bidang dan keilmuan lain. Pemanfaatan DM dengan pengolahan melalui *Artificial Neural Networks* (ANN) dan *Support Vector Machines* (SVMs), dapat menghasilkan model perkiraan dengan tingkat ketepatan cukup tinggi (Cortez, 2013).

Melalui beberapa metode terkini, DM menjadi sebuah pendekatan yang sangat kuat dalam mengolah susunan data (Cortez, 2013). Studi ini telah melakukan pendekatan penyusunan model perkiraan tingkat pelayanan jalan (model IRI) dengan DM berdasarkan

data yang sudah tersusun, dengan tujuan sebagai dukungan pengembangan Sistem Manajemen Perkerasan Jalan di Indonesia.

DATA MINING

Pengambilan keputusan dalam ruang lingkup yang cukup kompleks seperti dalam teknik sipil, sangat tergantung terhadap kemampuan kognitif seseorang pengambil keputusan tersebut, sehingga secara langsung dapat berdampak terhadap kualitas putusannya itu sendiri. Saat ini, dengan dukungan teknik komputer dan algoritma, model interpretasi dan dukungan pengambilan keputusan sudah sangat berkembang (Cortez, 2010). Seluruh data harus menjadi bahan pertimbangan dalam pengambil keputusan dengan berbagai metode yang telah berlaku secara umum. Data tersebut akan menjadi informasi yang bermanfaat apabila mampu diinterpretasikan secara tepat. Model interpretasi data tersebut selanjutnya disebut *Data Mining* (DM).

DM telah menguat menjadi sebuah bentuk konsentrasi dalam ilmu kecerdasan buatan. Sejak tahun 1960 DM ini terus dikembangkan untuk memaksimalkan kemampuan basis data yang kemampuan dan kapasitasnya juga terus meningkat secara pesat. Perkembangan DM ini telah mampu mendorong penggunaan data mentah dalam basis data menjadi sebuah sumber yang sangat berarti dalam pembentukan berbagai model perkiraan (Liao, 2012). Basis data akan tetap merupakan sekedar data mentah saja apabila tidak dapat dilakukan interpretasi terhadap data yang telah dikumpulkan tersebut.

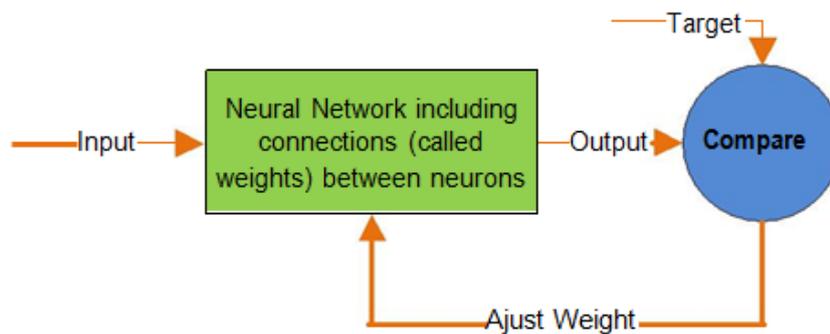
Kemampuan DM melakukan model interpretasi secara akurat karena didukung oleh kapasitas DM dalam membaca data yang sangat besar (Weiss, 1998). Dengan model DM, seberapa besar pun basis data yang tersedia akan mampu diambil, ditabulasi, diolah dan kemudian dilakukan model interpretasi dengan baik sesuai dengan kaidah statistika yang sudah berlaku umum. Seperti halnya survei langsung, kuesioner, dan tabulasi visual, sejarah tingkat layanan jalan (*historical pavement performance*) akan mendukung kemampuan DM dalam membantu mengembangkan sistem manajemen perkerasan jalan secara praktis (Lamprey, 2008). Model DM yang dikembangkan dalam studi ini diharapkan dapat melakukan interpretasi yang cukup mendasar agar sejarah perkerasan dapat dijadikan sebagai data awal untuk melakukan pemeliharaan dan peningkatan mutu jalan yang optimal.

ARTIFICIAL NEURAL NETWORK AND SUPPORT VECTOR MACHINES

Metode DM

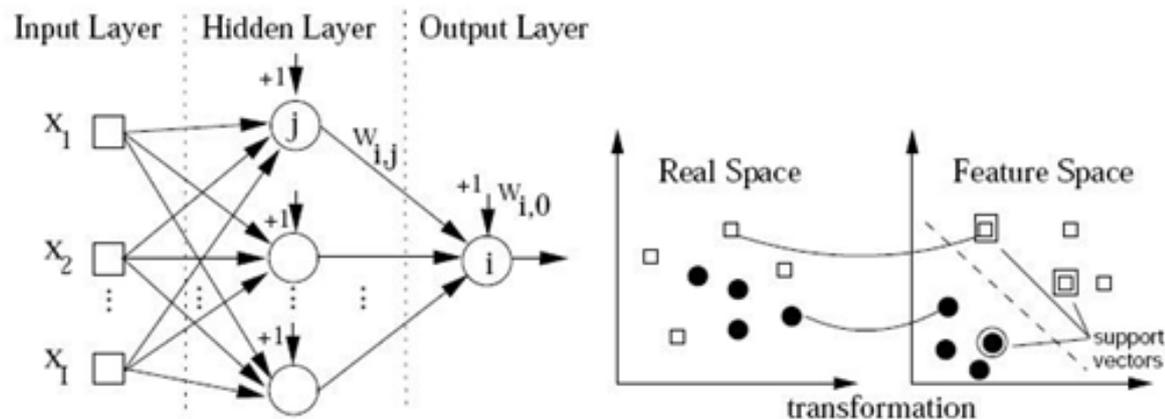
Metode DM cukup beragam, berbagai jenis teknik pendekatan dapat dilakukan dengan dasar teori statistik. Selain itu DM juga sangat terbuka dengan pendekatan kecerdasan buatan dengan berbagai perkembangan terkini, salah satu metode yang saat ini cukup berkembang adalah pendekatan ANN dan SVMs. Pendekatan untuk model nonlinier

sangat baik dengan model ANN dan SVMs yang dikembangkan dalam DM (Cortez, 2010). ANN terdiri atas elemen-elemen sederhana yang beroperasi secara paralel. Elemen ini terinspirasi oleh sistem saraf biologis. Seperti di alam fungsi jaringan ditentukan terutama oleh hubungan antara komponen. ANN dapat dilatih untuk melakukan fungsi tertentu dengan menyesuaikan nilai-nilai koneksi antara elemen. Umumnya ANN disesuaikan atau dilatih (*training*) sehingga input tertentu diarahkan ke target akhir yang spesifik, yang konsepnya ditunjukkan pada Gambar 1.



Gambar 1 Konsep *Neural Network* (Demuth, 2009)

Pada konsep tersebut jaringan disesuaikan berdasarkan perbandingan output dan target yang secara terus menerus dilakukan penyesuaian hingga output jaringan sesuai dengan target. Biasanya jumlah pasangan antara input dengan output atau target tersebut sangat berpengaruh terhadap hasil *training*. Kelompok *training* hasil jaringan akan membentuk pola tersendiri dan memperlihatkan perubahan berdasarkan seluruh kelompok vektor input. Jaringan saraf telah di-*training* untuk melakukan fungsi kompleks dalam berbagai bidang dengan aplikasi meliputi pengenalan pola, identifikasi, klasifikasi, visualisasi, dan sistem kontrol. Saat ini ANN dapat di-*training* untuk memecahkan masalah yang dianggap sulit oleh komputer konvensional atau manusia (Demuth, 2009).



Gambar 2 Tahapan Presepsi (Kiri) dan Contoh Kombinasi Transformasi Presepsi dengan SVM (Kanan) (Cortez, 2010)

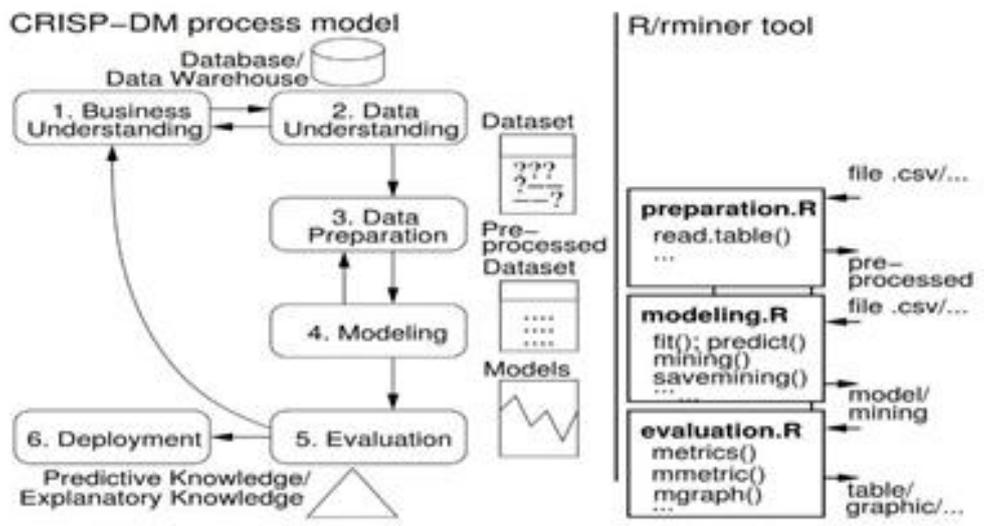
Sedangkan SVMs, sebagai pengembangan model dalam DM, akan melakukan model interpretasi secara cerdas terhadap data rujukan yang dikumpulkan dalam bentuk *basis data* dengan kondisi dan algoritma tertentu mengikuti pola dan ruang peluang, seperti terlihat pada Gambar 2. Selanjutnya SVMs akan memilih dan menampilkan keluaran hasil interpretasi yang diharapkan melalui kombinasi ruang kemungkinan (Cortez, 2010).

Bahasa R

Bahasa R adalah bahasa pemrograman untuk melakukan pendekatan statistika dan grafis secara komputasi, yang dalam studi ini disebut R Tool. Bahasa R ini merupakan salah satu proyek pengembangan GNU General Public Licenses, yang hampir sama dengan bahasa S yang dikembangkan di Bell Laboratories (sebelumnya AT & T dan sekarang Lucent Technologies) oleh John Chambers dan rekan. Bahasa R dapat dianggap sebagai implementasi pengembangan dan penyempurnaan bahasa S. Bahasa R merupakan aplikasi open source dan merupakan bahasa pemrograman tingkat tinggi, yang biasa digunakan untuk analisis statistika dan data.

Komunitas pengembang Bahasa R sangat aktif sehingga banyak sekali pengembangan paket (*library*) baru. Dalam perspektif ini R Tool dapat dilihat sebagai alat open source untuk dapat dikembangkan di seluruh dunia dan dalam semua bidang (Cortez, 2010). Salah satu paket tersebut adalah *rminer* (Cortez, 2013), yang bertujuan memfasilitasi penggunaan algoritma DM pada kedua klasifikasi sebagai alat bantu para peneliti dan pengembang dalam berbagai bidang keilmuan. Karena Bahasa R menggunakan bahasa berorientasi objek, *rminer* menyajikan kumpulan fungsi penting agar dapat diaplikasikan pada berbagai permasalahan karena dilengkapi dengan berbagai fungsi, di antaranya *fit*, *predict*, *mining*, *mgraph*, *metric*, dan *mmetric*. Tahapan penyusunan model dengan DM dengan R Tool dapat dilihat pada Gambar 3.

Paket yang dikembangkan dalam DM juga mampu melakukan proses optimasi dengan berbagai fungsi yang disesuaikan (Marques, 2008). Pada penentuan fungsi pertama ditentukan terlebih dahulu persamaan algoritma untuk tiap tahapan. Kemudian dalam fungsi lanjutan dapat ditentukan persamaan dan algoritma monitoring untuk dapat melihat bentuk optimasi dari fungsi sebelumnya. Data setiap tahapan kemudian disimpan dalam bentuk obyek dalam fungsi R Tool, yang dapat memberikan pemilihan kromosom yang paling efisien dari setiap tahapan, yang akan pindah ke tahapan berikutnya bersama dengan model yang dihasilkan dari *crossover* dan mutasi tahapan sebelumnya. Pada tahapan puncak kromosom dengan kinerja terbaik akan dipilih sebagai persamaan, algoritma, dan model yang dianggap optimal. Keuntungan lain DM ini adalah fleksibilitas yang tinggi dan kemudahan instalasi paket terkait dengan beberapa teknologi yang berbeda ke dalam sistem yang sama, yang memberikan peluang untuk melakukan integrasi DM dan jenis teknologi optimasi modern lainnya ke dalam sistem yang sama. Penggunaan R Tool dalam studi ini untuk membantu penyusunan algoritma model perkiraan tingkat kerataan permukaan jalan (*roughness index*) sampai mendapatkan model yang cukup fit dengan tingkat kepercayaan 95 % dengan maksimal iterasi 10.000 kali.



Gambar 3 Proses DM dengan R Tool (Cortez, 2010)

INTERNATIONAL ROUGHNESS INDEX (IRI)

Internasional Roughness Index (IRI) mulai dikembangkan pada tahun 1986 oleh Bank Dunia yang merupakan pengembangan konsep NCHRP. Pertama kali diperkenalkan dalam International Road Roughness Experiment (IRRE) yang dilaksanakan di Brasil. IRI diukur dengan mengumpulkan output mobil uji atau langsung dibagi dengan panjang profil untuk menghasilkan ringkasan indeks kerataan. IRI telah diterima secara internasional sebagai indikator tingkat layanan jalan yang dapat terus dikalibrasi untuk wilayah dan waktu yang berbeda. IRI dapat disebut pula sebagai parameter kekasaran yang dihitung dari jumlah kumulatif naik-turunnya permukaan arah profil memanjang dibagi dengan jarak atau panjang permukaan yang diukur (Suwardo, 2004).

Kerataan atau *Roughness* dapat didefinisikan sebagai *the deviation of a surface from a true planar surface with characteristic dimensions that affect vehicle dynamics and ride quality* (ASTM, 2003). Tingkat kerataan permukaan jalan merupakan indikator penting keselamatan karena secara langsung mempengaruhi pengemudi dan kendaraan. Kerataan terkait dengan amplitudo dan frekuensi distorsi perkerasan, karakteristik suspensi kendaraan, dan kecepatan kendaraan.

Tingkat pelayanan jalan merupakan kemampuan permukaan jalan dalam mengakomodasi harapan pengguna jalan pada tingkat kenyamanan yang wajar. Pengukuran kerataan diperlukan untuk melengkapi komponen penilaian kondisi permukaan jalan. Sampai saat ini *roughness index* masih merupakan salah satu alat ukur tingkat layanan jalan di Indonesia yang digunakan dalam sistem manajemen perkerasan jalan.

PEMODELAN *ROUGHNESS INDEX* DENGAN DATA MINING

Pada makalah ini diuraikan model IRI menggunakan pendekatan DM dengan *library rminer*. Model IRI dikembangkan dengan data lalu lintas berupa pencatatan *Equivalent Single Axle Load* (ESAL), IRI awal (IRI_0), *Structural Number* (SN), serta umur perkerasan (*Age*) pada jaringan jalan nasional di Wilayah Jawa Barat, dari tahun 2009 sampai dengan 2014 (Gambar 4). Selanjutnya, melalui pendekatan DM, data tersedia diekstraksi dengan kemampuan matematika, algoritma, dan statistika yang sudah disusun berdasarkan model IRI yang dirancang.



Gambar 4 Model IRI dengan DM

Untuk mengurai data mentah yang telah diekstraksi, ANN dan SVMs yang sudah dirancang dan dikembangkan dari *R Tool-library rminer* dilakukan modifikasi algoritma untuk mendapatkan model nilai IRI. *R Tool* ini diharapkan mampu memberikan interpretasi yang tepat dalam memodelkan nilai IRI pada kerangka waktu yang ditetapkan dengan mempertimbangkan berbagai kondisi yang memengaruhinya.

Dengan menggunakan model ANN standar dalam DM yang dikembangkan dengan algoritma model nilai IRI, bobot hubungan neuron ditentukan melalui proses iterasi *training*. Proses *training* melibatkan pola hubungan input dan target terdahulu dalam *dataset training* pada ANN. Bobot hubungan neuron dalam tingkatan yang berbeda secara iterasi disesuaikan (*adjust weight*). Proses *training* ini dilakukan dengan iterasi sebanyak 10.000 kali dalam tiap tahapan. Setelah prosedur *training* selesai, pola ANN hasil *training* digunakan untuk memeriksa efektivitas proses pemodelan selanjutnya. Kemudian *dataset* pengujian yang lengkap dimasukkan ke proses ANN *training*, dan secara bertahap tingkat kesalahan pengujian dihitung. Jika kesalahan pengujian masih dapat diterima, model ANN dianggap wajar. Proses pemodelan dari *Input Layer*, *Hidden Layer*, sampai dengan *Output Layer* yang mengacu pada Gambar 2 dan Gambar 4 dapat diuraikan seperti Persamaan (1):

$$y_i = f_i(w_{i,0} + \sum_{j=i+1}^{I+H} f_j(\sum_{n=1}^I x_n w_{m,n} + w_{m,0}) w_{i,n}) \quad (1)$$

dengan:

- y_i = output hasil *network i*
- x_n = input parameter (ESAL, IRI₀, SN, Age)
- $w_{i,j}$ = bobot (*weight*) dari node *i* ke node *j*
- f_j = *activation function* untuk node *j*
- H = neuron untuk layer *H*

Selanjutnya hasil output ANN tersebut secara iterasi dimodelkan nilai perkiraanya (*prediction*) dengan mengikuti konsep kombinasi *output* dan target melalui penyesuaian beban node (*weight adjust*), menggunakan persamaan sebagai berikut:

$$p(i) = \frac{\exp(y_i)}{\sum_{c=1}^{N_c} \exp(y_c)} \quad (2)$$

dengan:

- $p(i)$ = probabilitas nilai perkiraan (*prediction*) *i*
- N_c = linear *output* neuron

Perbandingan model untuk mencoba model ANN yang berbeda dilakukan dengan membandingkan *Mean Square Error* (MSE) pada tahap pengujian. Akhirnya model ANN dipilih dengan MSE terkecil dan tingkat fit (R^2) terbesar. Tingkat fit nilai IRI hasil pengukuran dengan model IRI hasil DM (ANN) hasil studi ini dapat dilihat pada Gambar 5 (kiri). Sumbu horizontal (sumbu x) menunjukkan nilai IRI hasil pengukuran dan sumbu vertikal (sumbu y) menunjukkan model nilai IRI hasil DM.

Selanjutnya disusun algoritma praktis pada *library rminer SVMs* untuk mendapatkan model perkiraan nilai IRI serta mengukur dan membandingkan tingkat kesesuaiannya. Pendekatan DM dengan SVMs ini diharapkan mampu memberikan hasil terbaik dengan kondisi *basis data* yang lebih sedikit. Selain itu, untuk dapat memastikan solusi secara global yang optimal pada tahapan kedua, sebagai hasil teoritis dan representasi yang diiterasi secara terintegrasi. Salah satu langkah dalam penelitian ini memasukan *subfield* yang diperluas untuk mendapatkan kecerdasan buatan dalam *machine learning* (ML) yang disediakan. Pendekatan model SVMs yang menggunakan *library rminer* mengikuti persamaan sebagai berikut:

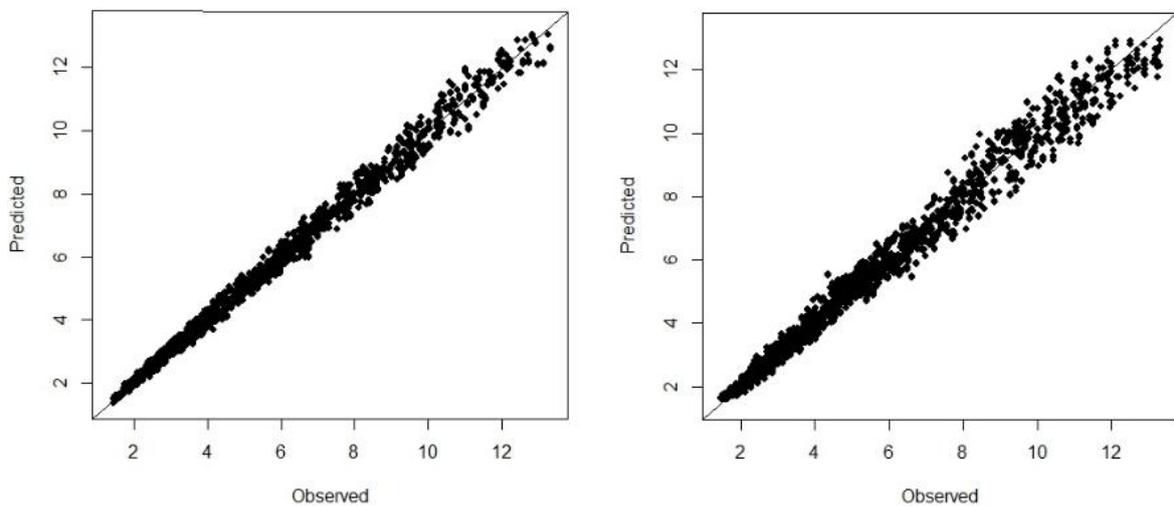
$$f(x_i) = \sum_{j=1}^m y_j \alpha_j K(x_j, x_i) + b$$
$$p(i) = \frac{1}{1 + \exp(Af(x_i) + B)} \quad (3)$$

dengan:

- y_i = $\in \{-1, 1\}$
- b & α_j = koefisien model

Model SVMs ini diiterasi yang digunakan berjenjang dari 20, 500, 1.000, dan 10.000 kali. Tingkat kesesuaian nilai IRI hasil pengukuran dengan model IRI hasil DM (SVMs) studi ini dapat dilihat pada Gambar 5 (kanan). Sumbu horizontal (sumbu x) menunjukkan nilai IRI hasil pengukuran dan sumbu vertikal (sumbu y) menunjukkan model nilai IRI hasil DM.

Untuk mencapai tingkat akurasi prediksi yang tinggi, pada penelitian ini dilakukan penguraian model *data-driven*. Hal ini biasa dilakukan terutama dalam bidang keteknikan dengan tetap mengkombinasikan algoritma ANN dan SVMs, dengan menggunakan ekspresi matematika yang disederhanakan. Prosedur aplikasi yang tersedia mampu untuk "membuka" model IRI data terbangun. Model *interpretability* diukur dengan mengukur variabel input yang ditabulasi sehingga mendapatkan model IRI yang cukup baik. Sebagai bahan pembandingan sederhana, ditambahkan pemodelan dengan *Linear Regression* (LR). Pada Tabel 1 diuraikan hasil prediksi beserta indikasi statistiknya.



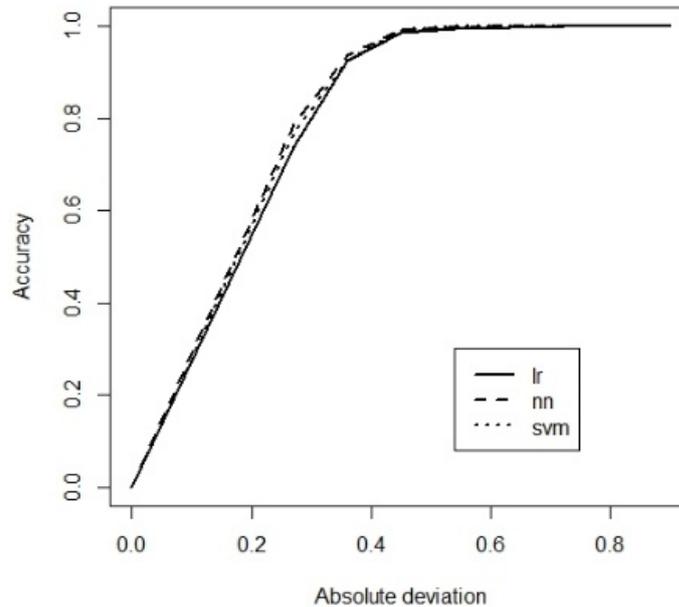
Gambar 5 Perbandingan Model IRI dengan ANN (Kiri) dan SVMs (Kanan)

Tabel 1 Error Metrics Pendekatan DM untuk Model IRI
(*Test Set Values, Best Values* Ditebalkan)

Model	MAD	RMSE	R ²
LR	0,89 ± 0,00	1,13 ± 0,00	0,82 ± 0,00
ANN	0,53 ± 0,00	0,71 ± 0,00	0,91 ± 0,00
SVMs	0,67 ± 0,03	0,81 ± 0,04	0,90 ± 0,01

Hasil analisis pemodelan dengan interval tingkat kepercayaan 95 % untuk masing-masing variabel telah sesuai dengan distribusi *t-student*. Model DM diiterasi dengan menggunakan *dataset* dari *basis data* yang sama.

Tabel 1 menunjukkan kemampuan pemodelan. Hasil penelitian ini menunjukkan bahwa nilai IRI dapat dimodelkan secara akurat dengan DM melalui pendekatan ANN dan model SVMs dengan tingkat akurasi cukup baik, seperti yang dapat dilihat pada Gambar 6.



Gambar 6 Kurva REC untuk Model LR, ANN dan SVMs

KESIMPULAN

Pada penelitian ini, dengan *basis data* yang ada, telah dilakukan ekstraksi terhadap data *ESAL*, Structural Number (SN), nilai IRI awal (IRI_0) dan umur perkerasan (*Age*). Kemudian dilakukan pemodelan IRI dengan DM melalui pendekatan model ANN dan SVMs. Untuk menghasilkan model yang akurat, dilakukan iterasi dengan input yang sama dari sumber *dataset* dalam *basis data* IIRMS.

Model nilai IRI dengan pendekatan DM ini cukup akurat, serta mampu memberikan tingkat akurasi yang baik dengan R^2 sebesar 0,91. Diharapkan model IRI dengan pendekatan DM ini dapat memberikan dukungan terhadap sistem manajemen perkerasan dalam melakukan penjadwalan dan strategi pemeliharaan secara optimal.

UCAPAN TERIMA KASIH

Ucapan terima kasih disampaikan kepada Ditjen Bina Marga, Kementerian Pekerjaan Umum, dan Balai Besar Pelaksanaan Jalan Nasional IV, Jakarta, atas dukungan data IIRMS yang telah digunakan. Demikian pula ucapan terima kasih disampaikan kepada Centre Algoritmi, School of Engineering, University of Minho, Portugal, atas dukungan pengolahan pemodelan *data mining*.

DAFTAR PUSTAKA

- American Society for Testing and Materials. 2003. *Standard Terminology Relating to Vehicle-Pavement Systems*. West Conshohocken, PA: ASTM International.
- Cortez, P., dan Embrechts, M.J. 2013. *Using Sensitivity Analysis and Visualization Techniques to Open Black Box Data Mining Model*. Information Sciences, 225: 1-17.
- Cortez, P. 2010. *Data Mining with Neural Networks and Support Vector Machines Using the R/rmine R Tool*. In P. Perner (Ed.), *Advances in Data Mining, 10th Industrial Conference on Data Mining (ICDM 2010)*. Berlin.
- Demuth, H., Hagan, M dan Beale, M. 2009. *Neural Network Toolbox*. User guide, Version 6. Natick: The MathWorks Inc.
- Kropac, O. dan Mucka, P. 2005. *Be Careful When Using The International Roughness Index as an Indicator of Road Unevenness*. Journal of Sound and Vibration, 287: 989-1003.
- Lampthey, G., Labi, S., dan Li, Z. 2008. *Decision Support for Optional Scheduling of Highway Pavement Preventive Maintenance within Resurfacing Cycle*. In Elsevier Decision Support System, 46 (1): 376-387.
- Lee, J. dan Madanat, S. 2014. *Joint Optimization of Pavement Design, Resurfacing and Maintenance Strategies with History-Dependent Deterioration Models*. Transportation Research Part B, 68: 141-153.
- Liao, S., Chu, P., dan Hsiao, P. 2012. *Data Mining Techniques and Applications-A Decade Review from 2000 to 2011*. Expert Systems with Applications, 39 (12): 11303-11311.
- Marques, R., Correia, A. G., dan Cortez, P. 2008. *Data Mining Applied to Compaction of Geomaterials*. Eighth International Conference on The Bearing Capacity of Roads, Railways and Airfields, Illinois. 597-605
- Suwardo dan Sugiharto. 2004. *Tingkat Kerataan Jalan Berdasarkan Alat Rolling Straight Edge untuk Mengestimasi Kondisi Pelayanan Jalan (PSI dan RCI)*. Simposium VII Forum Studi Transportasi antar Perguruan Tinggi. Bandung.
- Tinoco, J., Correia, A.G., dan Cortez, P. 2014. *Support Vector Machines Applied to Uniaxial Compressive Strength Prediction of Jet Grouting Columns*. Computers and Geotechnics, 55:132-140.
- Tranggono, M. 2013. *Kajian Penggunaan HDM-4 untuk Sistem Pengelolaan Perkerasan Jalan di Indonesia*. Jurnal Transportasi, 13 (2): 135-144.
- Weiss, S.H. dan Indurkha, N. 1998. *Predictive Data Mining: A Practical Guide*. San Francisco, CA: Morgan Kaufmann Publishers.
- Zhou, G. dan Wang, L. 2012. *Co-Location Decision Tree for Enhancing Decision-Making of Pavement Maintenance and Rehabilitation*. Transportation Research, Part C21: 287-305.

Zouch, M., Yeung, T., Castanier, B., dan Lorino, T. 2012. *Application of Bivariate Deterioration Model for A Pavement Management Optimization*. Social and Behavioral Sciences, 48: 196-204.