



PREDIKSI KUALITAS LAPORAN KEUANGAN KEMENTERIAN NEGARA/LEMBAGA MENGGUNAKAN *MACHINE LEARNING*

Teguh Puspadoyo¹, Widha Adinata², Laode Atthar Alfikry³,

Tyas Ayu Prasanti⁴, Silvi Yuniar⁵

^{1,2,3,4,5} Direktorat Jenderal Perbendaharaan, Kementerian Keuangan, Jakarta

Alamat Korespondensi: widhaadinata@gmail.com

Abstract

Quality financial reports are one of the tools in realizing government accountability. However, not all State Ministries/Agencies yet have received the best opinion. Based on previous research, several factors have a significant influence on the quality of financial reports. Therefore, this study aims to analyze the influencing factors and also make predictions and classification of quality of state ministries/agencies of financial reports using machine learning techniques. The sample used in this study was 256 state ministries/agencies from 2018-2020. The results show that cash fraud, findings, follow-up to BPK's recommendations, the money supply/additional money supply, and realization have a strong influence in determining quality of financial reports. In addition, with the Support Vector Machine model, better classification predictions are obtained for quality of state ministries/agencies of financial reports.

Abstrak

Laporan keuangan yang berkualitas menjadi salah satu *tools* dalam mewujudkan akuntabilitas pemerintah. Namun, belum seluruh kementerian negara/lembaga mendapatkan opini terbaik. Berdasarkan penelitian, beberapa faktor memiliki pengaruh yang signifikan terhadap kualitas laporan keuangan. Oleh karenanya, riset ini bertujuan untuk menganalisis faktor yang berpengaruh sekaligus membuat prediksi klasifikasi atas kualitas laporan keuangan kementerian negara/lembaga melalui teknik *machine learning*. Sampel yang dipakai pada penelitian ini sebanyak 256 kementerian negara/lembaga dari tahun 2018-2020. Hasil penelitian menunjukkan bahwa *fraud* kas, temuan, tindak lanjut atas rekomendasi BPK, UP/TUP, dan realisasi mempunyai pengaruh yang kuat dalam menentukan kualitas laporan keuangan. Selain itu, dengan model *Support Vector Machine* didapatkan prediksi klasifikasi yang lebih baik atas Kualitas laporan keuangan kementerian negara/lembaga.

Keywords: Audit, Kualitas Laporan Keuangan, *Machine Learning*, *Support Vector Machine*
JEL Classification: M41, M42



PENDAHULUAN

Akuntabilitas merupakan sebuah amanat Undang-Undang yang harus diimplementasikan. Dalam Paket Undang-Undang Keuangan Negara (UU Nomor 17 Tahun 2003, UU Nomor 1 Tahun 2004, dan UU Nomor 15 Tahun 2004), telah mengatur bagaimana pola pengelolaan keuangan negara hingga pelaporan dan pemeriksaannya. Laporan keuangan yang berkualitas menjadi salah satu *tools* dalam mewujudkan akuntabilitas pemerintah (Benito dalam Setyanto & Ritchi, 2018). Selain itu, laporan keuangan juga digunakan untuk mengetahui nilai sumber daya ekonomi yang dimanfaatkan dalam pelaksanaan kegiatan operasional pemerintah, menilai kondisi keuangan, dan mampu membantu menentukan ketaatan terhadap peraturan perundang-undangan (Windarsih, 2015).

Laporan keuangan harus berkualitas untuk mendukung pengambilan kebijakan berbagai pihak. Informasi dalam laporan keuangan harus bermanfaat bagi para pemakai (Simanungkalit, 2015). Opini Badan Pemeriksa Keuangan (BPK) menjadi salah satu indikator penilaian kualitas laporan keuangan pengelolaan. Opini dari BPK terbagi atas beberapa tingkatan, yakni Tidak Wajar, Tidak Memberikan Pendapat (TMP), Wajar Dengan Pengecualian (WDP), dan yang tertinggi Wajar Tanpa Pengecualian (WTP).


Standar Akuntansi Pemerintahan dalam Peraturan Pemerintah (PP) Nomor 71 Tahun 2010 menjelaskan bahwa karakteristik kualitatif laporan keuangan yakni ukuran normatif yang harus diwujudkan dalam informasi

akuntansi supaya mampu memenuhi tujuannya. Dalam kerangka konseptual akuntansi pemerintahan, unsur pembentuk kualitas informasi yakni relevan, andal, dapat diperbandingkan, dan dapat dipahami. Dalam rangka mewujudkan kualitas informasi tersebut, pemerintah pusat membuat dan mengembangkan Sistem Akuntansi Pemerintah Pusat (SAPP) yang akan menghasilkan Laporan Keuangan Pemerintah Pusat (LKPP) sebagaimana diatur dalam Peraturan Menteri Keuangan Nomor 215/PMK.05/2016. SAPP tersebut terdiri dari dua subsistem, yakni Sistem Akuntansi Bendahara Umum Negara (SA-BUN) dan Sistem Akuntansi Instansi (SAI). SA-BUN akan menghasilkan Laporan Keuangan BUN (LK-BUN) dan SAI akan menghasilkan Laporan Keuangan Kementerian negara/lembaga (LKKL).

Kualitas LKPP dipengaruhi oleh kualitas LK-BUN dan LKKL karena merupakan konsolidasi dari kedua laporan tersebut. Semenjak tahun 2016 hingga tahun 2020, LKPP dan LK-BUN selalu mendapatkan opini WTP dari BPK. Lain halnya dengan LKKL, semenjak tahun 2016 sampai dengan 2020 belum pernah seluruh LKKL mendapatkan opini WTP sebagaimana disajikan dalam Grafik 1.

Selain itu, Presiden Republik Indonesia telah menyatakan bahwa opini WTP bukanlah sebuah prestasi melainkan kewajiban dalam mengelola anggaran negara. Hal ini berarti bahwa masih terdapat kementerian negara/lembaga yang belum memenuhi kewajiban pengelolaan keuangan dengan baik.

Grafik 1. Perbandingan Persentase
 Perolehan Opini WTP LKPP dan LKKL
 tahun 2016 s.d. 2020



Sumber: LKPP dan LKKL (diolah)

Penelitian tentang faktor apa saja yang berpengaruh terhadap kualitas laporan keuangan yang dicerminkan dengan opini audit telah dilakukan oleh peneliti terdahulu dan hasilnya masih berbeda antar peneliti. Sutaryo et al. (2020) menemukan bahwa kompleksitas, ukuran, dan tipe pemerintah daerah, pengawasan keuangan, dan pengesahan atas APBD serta penyampaian Laporan Keuangan Pemda (LKPD) berpengaruh signifikan terhadap opini audit Pemda. Kewo & Afiah (2017) menemukan bahwa sistem pengendalian internal dan audit internal memiliki pengaruh positif dan signifikan secara parsial dan simultan terhadap kualitas laporan keuangan. Berbeda, Nurdiono et al. (2016) menemukan bahwa efektivitas pengendalian internal, kompetensi SDM, dan tindak lanjut atas rekomendasi BPK tidak berpengaruh signifikan terhadap opini audit LKPD. Beberapa penelitian tersebut mengambil fokus penelitian di pemerintah daerah.

Penelitian tentang faktor yang berpengaruh terhadap kualitas laporan keuangan di tingkat pemerintah pusat khususnya kementerian negara/lembaga sebagai sebuah konsolidasian seluruh satuan kerja (satker) dibawahnya masih sangat jarang. Simanungkalit (2015) yang mengambil objek satker di wilayah Banda Aceh dan menggunakan data primer menemukan bahwa penerapan SAP, mutu kinerja SDM, sistem pengendalian internal, komitmen institusi, dan penggunaan teknologi informasi berpengaruh terhadap kualitas laporan keuangan secara positif dan signifikan. Roni et al. (2019) menemukan bahwa penerapan SAP dan teknologi informasi berpengaruh positif signifikan sedangkan kompetensi SDM dan sistem rekonsiliasi tidak memiliki pengaruh terhadap kualitas laporan keuangan. Hanya Sari (2016) yang mencoba meneliti menggunakan objek kementerian negara/lembaga dan menggunakan data sekunder, dimana hasilnya ditemukan bahwa temuan, tindak lanjut pemeriksaan, dan kapasitas SDM pengelola keuangan memiliki pengaruh positif terhadap opini jika melihat kecukupan *disclosure*.

Faktor apa saja yang mempengaruhi kualitas laporan keuangan dan bagaimana penggunaan teknik *machine learning* untuk melakukan prediksi kualitas laporan keuangan menjadi latar belakang riset ini. Selain itu, dalam riset ini akan mengembangkan hasil dari penelitian sebelumnya dengan menggunakan sampel dari tahun yang lebih baru dan menggunakan lebih banyak variabel untuk mendapatkan hasil yang komprehensif. Beberapa variabel yang

ditambahkan yakni terkait adanya kasus yang terindikasi *fraud*, Indikator Kinerja Pelaksanaan Anggaran (IKPA), karakteristik pimpinan Kementerian negara/lembaga (K/L), dan umur K/L. Penelitian ini mengambil objek pada K/L karena belum seluruh K/L mendapatkan opini WTP, yang artinya masih terdapat K/L yang belum *comply* atas amanat Presiden di atas. Selain itu, sesuai grafik 1 di atas, masih terdapat *gap* antara opini LKPP dengan LKKL, padahal LKPP merupakan konsolidasian dari LKKL dan LK BUN. Hal ini berarti kualitas LKKL berpengaruh terhadap kualitas LKPP.

Sejalan dengan hal tersebut, riset ini juga mencoba untuk melakukan analisis menggunakan teknik *machine learning* untuk mendapatkan hasil yang komprehensif. Selain itu, riset ini juga akan menguji hipotesis faktor-faktor yang dicerminkan dari variabel dari penelitian terdahulu dan beberapa variabel baru yang menurut peneliti diduga sehingga dapat digunakan untuk prediksi atas kualitas LKKL. Sehingga riset ini diharapkan (1) mampu melakukan *exploratory data* faktor apa saja yang berpengaruh kuat terhadap kualitas LKKL; (2) membuat *modelling* klasifikasi untuk memperoleh prediksi kualitas LKKL; (3) memberikan rekomendasi sebagai mitigasi risiko dari hasil *modelling*/prediksi untuk memperkuat level pembinaan akuntansi kepada kementerian negara/lembaga. Oleh karenanya penelitian ini dapat bermanfaat dalam memberikan support bagi penentuan langkah dan strategi yang akan diambil dalam mitigasi resiko atas pencapaian kualitas LKKL. Sebab, turunnya kualitas LKKL tentu akan berdampak pada turunnya kredibilitas Kementerian Keuangan sebagai

Pembina/*Lead* Pengelola Keuangan Pemerintah Pusat.

TINJAUAN LITERATUR

Teori Keagenan (*Agency Theory*)

Menurut Zimmerman (1977) dalam suatu organisasi baik sektor swasta maupun sektor publik, masalah keagenan dapat terjadi. Rakyat sebagai prinsipal dalam pemerintahan mendelegasikan kewenangannya kepada pemerintah sebagai agen untuk mengelola sumber daya yang dimilikinya. Sari (2016) menyatakan bahwa Pemerintah memiliki akses langsung terhadap informasi, namun tidak demikian dengan rakyat, maka disinilah timbul asimetri informasi.

Asimetri informasi berkaitan dengan biaya keagenan atau biaya yang harus dikeluarkan supaya baik principal maupun agen sama-sama mendapatkan manfaat yang setara. Keberadaan dan besarnya biaya keagenan tergantung salah satunya pada sejauh mana biaya monitoringnya, dan apabila Biaya monitoringnya nol maka Biaya keagenan menjadi nol pula (Jensen & Meckling, 1976). Oleh sebab itu, demi efektivitas dan efisiensi dalam berbangsa dan bernegara, maka akuntabilitas yang dicerminkan dengan kualitas laporan keuangan menjadi syarat mutlak dan kredibilitas pemerintah selaku agen dapat dipercaya *principal*.

Opini

Atas pemeriksaan yang telah dilakukan auditor terhadap laporan keuangan, BPK akan memberikan pendapat/opini. Menurut Badan Pemeriksa Keuangan (2012), jenis opini dibedakan menjadi empat, yaitu 1) Wajar Tanpa Pengecualian (WTP), Wajar

Dengan Pengecualian (WDP), Tidak Wajar (TW), dan Tidak Memberikan Pendapat/*Disclaimer of Opinion* (TMP). Opini WTP menyatakan bahwa laporan keuangan menyajikan secara wajar, dalam semua hal yang material sesuai dengan Standar Akuntansi Pemerintahan (SAP). WDP menyatakan bahwa laporan keuangan menyajikan secara wajar, dalam semua hal yang material sesuai dengan SAP kecuali untuk dampak hal-hal yang berhubungan dengan yang dikecualikan. TW menyatakan bahwa bahwa laporan keuangan tidak menyajikan secara wajar dalam semua hal yang material sesuai dengan SAP. Sedangkan TMP atau *disclaimer* merupakan pernyataan bahwa pemeriksa tidak menyatakan opini atas laporan keuangan.

Ukuran Kementerian negara/lembaga

Penelitian Nuraeni (2014) menyatakan bahwa total aset memiliki pengaruh negatif yang signifikan terhadap kualitas audit dari sisi opini audit. Hubungan negatif antara total aset dengan kualitas audit dapat disebabkan oleh pelaksanaan pengelolaan aset pemerintah daerah yang belum baik. Hal ini diindikasikan dengan jumlah temuan audit yang terkait dengan manajemen aset yang menimbulkan kerugian yang tidak kecil. Sehingga semakin banyak aset yang dimiliki pemda, semakin besar juga kemungkinan penyalahgunaannya.

Penelitian tersebut dapat digunakan sebagai landasan untuk melakukan penelitian serupa pada kementerian negara/lembaga, dimana ukuran kementerian negara/lembaga selain diprosikan melalui total asetnya, dapat juga dilihat dari anggaran dan

realisasi belanjanya, termasuk jumlah DIPA.

Indikator Kinerja Pelaksanaan Anggaran (IKPA)

Berdasarkan Peraturan Direktur Jenderal Perbendaharaan Nomor 4/PB/2021, IKPA ditetapkan oleh Kementerian Keuangan selaku BUN untuk menilai kualitas kinerja pelaksanaan anggaran belanja K/L, yang meliputi aspek:

1. Kesesuaian antara Perencanaan dengan Pelaksanaan Anggaran

a. Revisi DIPA

$$RRev\ n = \frac{1}{Frekuensi\ Revisi\ n} \times 100$$

RRev n = Rasio Revisi DIPA triwulan ke-n

Frekuensi = Frekuensi Revisi DIPA pada

Revisi n = triwulan ke-n

b. Deviasi Halaman III DIPA

$$DevDIPAn = \frac{Real\ n - RPD\ n}{RPD\ n} \times 100$$

DevDIPAn = Deviasi Hal III DIPA bulan ke-n

Real n = Realisasi Anggaran bulan ke-n

RPD n = Rencana Penarikan Dana bulan ke-n

c. Pagu Minus

$$Pagu\ Minus = \frac{Nilai\ Pagu\ Minus}{Pagu\ DIPA} \times 100$$

2. Kepatuhan Terhadap Peraturan Perundang-undangan di Bidang Pelaksanaan Anggaran, terdiri dari:

a. Penyampaian Data Kontrak

$$RKDK = \frac{DKTW}{DK} \times 100$$

RKDK = Rasio Ketepatan Waktu Penyampaian Data Kontrak

DKTW = Jumlah Data Kontrak yang disampaikan tepat waktu

DK = Jumlah Data Kontrak yang disampaikan ke KPPN

- b. Pengelolaan Uang Persediaan (UP) dan Tambahan Uang Persediaan (TUP)

$$RKWUP = \frac{GUPTUPTW}{GUP TUP} \times 100$$

- RKWUP = Rasio Ketepatan Waktu Pertanggungjawaban UP dan TUP
- GUPTUPTW = Jumlah SP2D GUP dan PTUP yang Tepat Waktu
- GUPTUP = Jumlah Data Kontrak yang disampaikan ke KPPN

c. Penyampaian Laporan Pertanggungjawaban (LPJ) Bendahara

$$RKLPJ = \frac{LPJB TW}{LPJB} \times 100$$

- RKLPJ = Rasio Ketepatan Waktu Penyampaian LPJ Bendahara Pengeluaran
- LPJ TW = Jumlah LPJ Bendahara Pengeluaran yang disampaikan tepat waktu
- LPJB = Jumlah LPJ Bendahara Pengeluaran yang disampaikan ke KPPN
- Jumlah Data Kontrak yang disampaikan ke KPPN

d. Dispensasi Penyampaian Surat Perintah Membayar (SPM) Dihitung dari jumlah SPM yang mendapatkan dispensasi.

Subkriteria	Nilai
0 SPM	100
1 – 5 SPM	95
6 – 10 SPM	90
11 – 20 SPM	85
>20 SPM	80

3. Efektivitas Pelaksanaan Anggaran

a. Penyerapan Anggaran

$$NKPan = \frac{PAn}{TAn} \times 100$$

- NKPan = Nilai Kinerja Penyerapan Anggaran triwulan ke-n
- PAn = Penyerapan Anggaran triwulan ke-n
- TAn = Target Penyerapan Anggaran triwulan ke-n

b. Penyelesaian Tagihan

$$RKPT = \frac{SPMLSTW}{SPMLS} \times 100$$

- RKPT = Rasio Ketepatan Waktu Penyelesaian Tagihan
- SPMLSTW = Jumlah SPM LS Kontraktual Non Belanja Pegawai yang tepat waktu disampaikan ke KPPN
- SPMLS = Jumlah SPM LS Kontraktual Non Belanja Pegawai yang disampaikan ke KPPN

c. Capaian Output

$$NKROn = \frac{CROn}{TROn} \times 100$$

- NKROn = Nilai Kinerja Capaian RO triwulan ke-n
- CROn = Capaian RO triwulan ke-n
- TAn = Target Capaian RO triwulan ke-n

d. Retur Surat Perintah Pencairan Dana (SP2D)

$$RRSP2D = \frac{RSP2D}{SP2D} \times 100$$

- RRSP2D = Rasio Retur SP2D
- RSP2D = Jumlah SP2D yang diretur
- SP2D = Jumlah SP2D yang diterbitkan

4. Efisiensi Pelaksanaan Anggaran

a. Pengembalian/Kesalahan SPM

$$RKSOM = \frac{SPMX}{SPM} \times 100$$

- RKSPM = Rasio Kesalahan SPM
- SPMX = Jumlah SPM yang ditolak oleh sistem
- SPM = Jumlah SPM yang disampaikan ke KPPN

b. Perencanaan Kas (Renkas)

$$RKRen = \frac{RenTW}{Renkas} \times 100$$

- RKRen = Rasio Ketepatan Waktu Renkas
- RenTW = Jumlah Renkas yang disampaikan tepat waktu
- Renkas = Jumlah Renkas yang disampaikan ke KPPN

Baiknya kualitas pelaksanaan anggaran akan tercermin juga dalam kualitas Laporan Keuangan. Mengingat dalam penelitian ini akan menganalisis klasifikasi kualitas Laporan Keuangan maka hanya komponen IKPA yang bersinggungan dengan temuan dan rekomendasi BPK sebagaimana tertuang dalam Laporan Hasil Pemantauan (LHP) atas Laporan Keuangan yang digunakan sebagai variabel.

Umur Kementerian Negara/Lembaga

Umur suatu organisasi dilihat dari tanggal pembentukan organisasi tersebut. Dalam konteks Pemerintah Pusat, Kementerian negara/lembaga berbeda pembentukannya yang dilandasi oleh berbagai ketentuan, bisa melalui amanat Undang-Undang maupun juga Keputusan Presiden/Peraturan Pemerintah. Setelah terbentuk, maka terdapat kewajiban untuk melaporkan aktivitas pengelolaan keuangannya. Umur atas organisasi telah menjadi subjek penelitian. Penelitian Sari (2016) menunjukkan bahwa variabel umur organisasi pemerintah berdampak negatif terhadap perolehan opini audit. Hal ini mengindikasikan bahwa semakin lama umur organisasi, semakin memungkinkan organisasi tersebut kesulitan menyajikan laporan keuangan sesuai dengan peraturan terbaru, sehingga berpotensi menyebabkan perolehan opini audit menjadi buruk.

Sementara itu, fenomena yang berbeda diungkapkan oleh Fatimah et al. (2014) menyimpulkan bahwa umur pemerintah daerah tidak berpengaruh pada penerimaan opini WTP. Hal ini dimungkinkan karena daerah yang baru terbentuk tidak menjadi penghalang kemampuan pemda tersebut dalam

menghasilkan laporan keuangan sesuai ketentuan. Karena pemda yang baru terbentuk cenderung memiliki permasalahan yang lebih sedikit dan anggaran yang lebih kecil dibandingkan pemerintah daerah yang lama terbentuk sehingga peluang untuk memperoleh WTP lebih besar.

Karakteristik Pimpinan Kementerian Negara/Lembaga

Pimpinan Kementerian negara/lembaga sebagai *Chief Operating Officer* bertanggung jawab langsung atas Kementerian negara/lembaga yang dipimpin termasuk dalam proses pengambilan keputusan. Tentu saja, baik secara langsung maupun tidak langsung hal ini juga akan mempengaruhi kualitas laporan keuangan yang disusun. Karakteristik pimpinan Kementerian negara/lembaga ini dapat dilihat dari tingkat dan jenis pendidikan, serta afiliasi dengan partai politik.

Berdasarkan penelitian Wicaksono (2012) dalam Sari (2016) menyimpulkan bahwa pimpinan daerah lulusan pendidikan akuntansi akan mendorong pemdanya untuk dapat menyusun laporan keuangan yang berkualitas dalam rangka meningkatkan perolehan opini audit. Sementara itu kaitannya dengan afiliasi dengan partai politik, didukung oleh hasil penelitian Cheng (1992) yang menyatakan bahwa lingkungan politik berpengaruh pada tingkat pengungkapan dalam laporan keuangan.

Temuan

Menurut Bastian dalam Munawar & Abdullah (2016) temuan merupakan hasil pemeriksaan/audit yang menjelaskan semua informasi penting

terkait dengan masalah audit tertentu. Jenis temuan dibedakan menjadi dua, yaitu temuan atas audit Sistem Pengendalian Intern (SPI) dan temuan atas audit kepatuhan terhadap peraturan perundang-undangan. Hasil penelitian Munawar & Abdullah (2016) menunjukkan bahwa temuan audit atas SPI dan kepatuhan peraturan perundang-undangan berpengaruh negatif terhadap perolehan opini LKPD.

Tindak Lanjut Atas Rekomendasi BPK

Atas kesalahan dalam pertanggungjawaban keuangan publik, Kementerian negara/lembaga bertanggungjawab untuk melakukan perbaikan setelah proses audit dilakukan. Hasil penelitian Sari (2016) menunjukkan bahwa tindak lanjut hasil pemeriksaan memiliki pengaruh positif yang signifikan terhadap opini audit melalui tingkat pengungkapan laporan keuangan. Semakin banyak rekomendasi BPK yang ditindaklanjuti semakin tinggi tingkat pengungkapan dalam LKKL, sehingga peluang perolehan opini Kementerian negara/lembaga juga semakin baik.

Fraud dengan Indikasi Korupsi

Tiga jenis *fraud* menurut *Association of Certified Fraud Examiner* (ACFE) yaitu penyimpangan atas aset, asersi yang menipu, dan korupsi (Priantara (2013) dalam Didi & Kusuma (2018). Dari ketiga jenis *fraud* tersebut yang paling banyak dijumpai pada sektor publik adalah korupsi. *Fraud* ini dapat ditemukan dalam temuan BPK sebagaimana tertuang pada Laporan Hasil Pemantauan (LHP). *Fraud* korupsi dibedakan menjadi Kas dan Non Kas.

Machine Learning

Machine Learning adalah model statistik atau algoritma yang dapat melakukan tugas spesifik tanpa perintah dengan mengandalkan sebuah pola tertentu (Sanjaya et al., 2020). *Machine learning* dibedakan menjadi dua yaitu *unsupervised learning* dan *supervised learning*. *Unsupervised learning* bekerja dengan cara menemukan pola atau fitur lalu mengkategorikan hasilnya sebagai sebuah prediksi. Berbeda, *supervised learning* bekerja dengan menggunakan data input dan output yang diinginkan. Bentuk umum dari *supervised learning* yakni klasifikasi dan regresi.

Random Forest Algorithm

Klasifikasi merupakan bagian dari model *machine learning* yang bekerja dengan cara melihat data dan mengelompokkan data berdasarkan kecenderungan data tersebut. *Random forest* merupakan kombinasi pohon prediktor, dimana setiap pohon bergantung pada nilai dari sampel *vector* acak secara independen dan berdistribusi sama untuk semua pohon (Breiman, 2001). Lebih lanjut, Breiman (2001) memilih model klasifikasi *random forest* karena kesalahan yang dihasilkan rendah, akurasi yang diberikan lebih bagus, dapat *menghandle* jumlah data *training* yang kompleks, dan mampu mengatasi data yang *missing*.

Penelitian menggunakan *random forest* juga telah dilakukan oleh para peneliti sebelumnya. Dhawangkhara (2017) membuat aplikasi prediksi intensitas hujan yang memberikan hasil prediksi berakurasi tinggi dengan lima kemungkinan yaitu tidak hujan, ringan, sedang, deras, dan sangat deras. Primajaya & Sari (2018) mencoba menguji implementasi *random forest*,

dan ditemukan bahwa *random forest* menghasilkan model prediksi hujan yang lebih bagus kinerjanya dibandingkan teknik *k-fold cross validation*. Sejalan, Sanjaya et al. (2020) juga menggunakan *random forest* dalam memprediksi kelalaian pinjaman bank dengan alasan bahwa *random forest algorithm* menghasilkan akurasi yang lebih tinggi dibanding algoritma lain. Selain itu *random forest* juga mampu bekerja baik pada data yang besar maupun data kelas yang tidak seimbang.

Decision Tree Algorithm

Salah satu metode nonparametrik yang dapat digunakan untuk klasifikasi melalui pembentukan pohon klasifikasi dengan cara membagi sekumpulan data secara iteratif menjadi sebuah simpul baru adalah *Decision tree* yang disebut juga CART (*Classification and Regression Tree*). Lewis (2000) mengungkapkan bahwa algoritma partisi rekursif biner digunakan pada metode ini. Jika variabel respon yang digunakan merupakan data ketgorik maka CART yang dihasilkan adalah pohon klasifikasi, sementara itu jika variabel respon merupakan data kontinu akan menghasilkan pohon regresi.

Penelitian menggunakan *decision tree* telah dilakukan oleh para peneliti sebelumnya. Yusuf (2007) membandingkan performa algoritma *decision tree* C5.0, C4.5, *Classification and Regression Tree*, dan CHAID untuk memprediksi status resiko kredit di Bank X dan dapat memberikan tingkat keakuratan di kisaran angka 87%. Setiadi (2015) juga menerapkan algoritma *decision tree* C4.5 untuk menilai rumah tunggal dan mendapatkan akurasi 72,73% dalam penilaian agunan kredit.

Hasil ini ia nyatakan lebih akurat daripada k-NN, *Random Tree*, *Naïve Bayes* maupun CART.

Support Vector Machine (SVM) Algorithm

Metode *machine learning* yang dapat digunakan untuk klasifikasi ataupun regresi salah satunya adalah SVM. Selain digunakan untuk mengklasifikasikan masalah secara linier, metode SVM saat ini telah berkembang untuk dapat menyelesaikan masalah secara *non-linier* dengan cara mencari *hyperlane* guna menentukan jarak maksimum antar kelas data (Oktaviani et al., 2014). Selain itu menurut Ustuner et al. (2015) dalam klasifikasi data dan pengolahan citra, SVM sebagai teknik *non-parametric* dapat digunakan. Parameter dan *kernel* diambil untuk menentukan tingkat akurasi. Setiap parameter dan *kernel* yang ditentukan pengguna akan memeberikan efek yang bervariasi.

Penelitian menggunakan SVM telah dilakukan oleh para peneliti sebelumnya. Agustina et al. (2018) menggunakan SVM di Desa Kidal, Kabupaten Malang, untuk mengklasifikasi Rumah Layak Huni. Selain itu, Fathurrahman & Putra (2021) juga menggunakan SVM untuk analisis perbandingan pengaruh pertumbuhan ekonomi terhadap tingkat kesejahteraan masyarakat di Desa Suralaga.

Naïve Bayes Algorithm

Klasifikasi Bayes merupakan bentuk klasifikasi statistik yang mampu memperkirakan kemungkinan keanggotaan suatu kelas. Sebagaimana teorema Bayes, klasifikasi ini memiliki kemampuan yang sejenis dengan *decision tree* maupun *neural network*.

Pada *database* yang sangat kompleks, klasifikasi ini mampu memberikan akurasi dan kecepatan yang tinggi (Purnama & Supriyanto, 2013).

Penelitian menggunakan *Naïve Bayes* telah dilakukan oleh para peneliti sebelumnya. Annur (2018) menggunakan metode *Naïve Bayes* untuk mengklasifikasikan masyarakat miskin dengan tingkat akurasi 73%, nilai *Precision* 92%, dan *Recall* 86%. Sejalan dengan itu, Surniandari et al. (2022) juga menggunakan *Naïve Bayes* untuk mengklasifikasikan penduduk dengan tingkat ekonomi rendah dengan hasil pengujian menunjukkan akurasi 100%, *precision* 100%, dan *recall* 100%.

METODE PENELITIAN


Research Design

Perancangan penelitian ini menggunakan proses sistematis dari alur kerja *machine learning*. Alur kerja *machine learning* secara umum terdiri dari *exploratory data*, *modelling*, *model evaluation*, dan diakhiri dengan *deployment* sebagaimana dijelaskan pada Gambar 1. Adapun penelitian ini merupakan penelitian kuantitatif dengan *machine learning* untuk memperoleh prediksi klasifikasi dari beberapa pilihan model yang akan diproses/dijalankan.

Sumber Data dan Variabel

Penelitian ini menggunakan data sekunder sepanjang tahun 2018-2020 dari jumlah sampel Kementerian negara/lembaga (K/L) yaitu tahun 2018 sebanyak 85 K/L, tahun 2019 sebanyak 86 K/L, dan tahun 2020 sebanyak 85K/L. Data diperoleh dari berbagai sumber. Diantaranya dari berkas arsip yang disediakan secara internal Direktorat Akuntansi dan Pelaporan Keuangan.

Gambar 1. Alur Kerja *Machine Learning*



Sumber: diolah penulis

Selain itu juga dari sistem dan aplikasi yang disediakan oleh Direktorat Jenderal Perbendaharaan, dan sumber lainnya.

Sumber data pertama adalah data Opini LKKL. Data Opini LKKL digunakan sebagai output dari prediksi. *Output* data terdiri dari klasifikasi opini WTP, WDP, TMP, dan TW seluruh LKKL dari tahun 2018-2020 dan bersumber dari LHP BPK atas LKKL.

Sumber data kedua adalah data Aset (AST). Data ini merupakan data total aset tiap Kementerian Negara / Lembaga dari tahun 2018-2020 yang diambil melalui Laporan Keuangan Neraca pada aplikasi e-rekon-LK di alamat e-rekon-lk.kemenkeu.go.id.

Sumber data ketiga adalah data Anggaran (ANG). Data ini merupakan data total anggaran tiap kementerian

negara/lembaga dari tahun 2018-2020 yang diambil melalui Laporan Realisasi Anggaran (LRA) pada aplikasi e-rekon-LK di alamat e-rekon-lk.kemenkeu.go.id.

Sumber data keempat adalah data Penyerapan. Data ini diformulasikan dari persentase realisasi terhadap anggaran tiap kementerian negara/lembaga dari tahun 2018-2020 yang diambil melalui Laporan Realisasi Anggaran (LRA) pada aplikasi e-rekon di alamat e-rekon-lk.kemenkeu.go.id.

Sumber data kelima adalah Jumlah DIPA. Data ini merupakan total DIPA satker yang dikelola kementerian negara/lembaga. DIPA satker diidentifikasi pada 3 digit kode BA tiap SP-DIPA memiliki kode yang sama dengan kode Bagian Anggaran masing-masing K/L. Data diambil dari Laporan Keuangan yang dihasilkan oleh masing-masing K/L dan aplikasi MEBE yang dikelola oleh Direktorat Pelaksanaan Anggaran, DJPb.

Sumber data keenam adalah data IKPA. IKPA disusun oleh Kemenkeu untuk menilai kualitas pelaksanaan anggaran belanja K/L. Berdasarkan pemantauan kami pada LHP BPK tahun 2018-2020, temuan dan rekomendasi BPK secara umum bersinggungan dengan komponen IKPA berikut, yaitu Pagu Minus (PGMIN), Data Kontrak (KONT), UP/TUP (UP/TUP), LPJ (LPJ), Dispensasi SPM (DSPM), Penyelesaian Tagihan (TAG), dan Kesalahan SPM (SPM). Seluruh data komponen IKPA tahun 2018-2020 bersumber dari aplikasi OMSPAN pada fitur Monev-PA di alamat spanint.kemenkeu.go.id.

Sumber data ketujuh adalah Umur Kementerian negara/lembaga. Data ini diperoleh dari LKKL tahun 2018-2020 pada bagian A.1. Profil dan Kebijakan

Teknis. Selain itu, apabila informasi tersebut tidak bisa kami dapat pada Laporan Keuangan, kami mengambilnya dari situs resmi kementerian negara/lembaga.

Sumber data kedelapan adalah Karakteristik Pimpinan kementerian negara/lembaga. Data ini diambil dari Laporan Keuangan Kementerian negara/lembaga tahun 2018-2020, terutama dengan melihat pencantuman gelar pendidikan dan NIP Pengguna Anggaran. Karakteristik pimpinan kementerian negara/lembaga yang menjadi variabel adalah 1) Tingkat Pendidikan, yang diambil dari pencantuman gelar pada nama Pengguna Anggaran, kemudian diklasifikasikan menjadi Non-Sarjana, Sarjana (S1), Magister (S2), Doktor (S3), 2) Jenis pendidikan, yang diambil dari pencantuman gelar pada nama Pengguna Anggaran, kemudian diklasifikasikan menjadi pendidikan ekonomi/akuntansi dan selain ekonomi/akuntansi, dan 3) Afiliasi Partai Politik, data diklasifikasikan menjadi Afiliasi Partai Politik dan Non Afiliasi Partai Politik. Diambil dari berbagai sumber berita yang kredibel. Namun apabila Pengguna Anggaran adalah ASN atau PPK, maka data langsung ditentukan adalah Non Afiliasi Partai Politik.

Sumber data kesembilan adalah Jumlah Temuan. Data ini diambil dari LHP BPK tahun 2018-2020. Adapun temuan dari BPK berdasarkan LHP dibedakan menjadi dua, yaitu Temuan SPI, dan Temuan Kepatuhan terhadap Peraturan Perundang-undangan.

Sumber data kesepuluh adalah Persentase Tindak Lanjut atas Rekomendasi BPK. Data ini diambil dari LHP BPK tahun 2018-2020. Kemudian

data rekomendasi yang telah sesuai ditindaklanjuti oleh kementerian negara/lembaga dibagi dengan jumlah rekomendasi BPK. Jumlah rekomendasi dihitung dari 1 tahun sebelum tahun LHP hingga tahun 2014. Sebagai contoh, untuk data persentase tindak lanjut dari LHP BPK tahun 2019, dihitung dari jumlah rekomendasi yang telah sesuai ditindaklanjuti dari tahun 2014-2018 dibagi dengan jumlah rekomendasi BPK dari tahun 2014-2018.

Sumber data terakhir adalah *Fraud* dengan Indikasi Korupsi. Data ini diambil dari Laporan Hasil Pemeriksaan (LHP) BPK tahun 2018-2020. Data ini kemudian dibedakan menjadi Kas dan Non-kas. Kas adalah data *fraud* yang melibatkan uang yang berada dalam pengawasan Bendahara seperti UP, TUP, dan LS Bendahara. Selain daripada itu dikategorikan sebagai Non-kas.

Dari sumber data tersebut di atas variabel target yang di gunakan yaitu Kualitas LK yaitu data Opini atas audit BPK. Sedangkan variabel *feature* yang digunakan untuk *predictor* dijelaskan sebagaimana pada tabel 1.

Tahapan Permodelan Machine Learning

Prediksi dan Permodelan disini menggunakan aplikasi Orange atau dikenal juga dengan sebutan Orange Data Mining yang merupakan perangkat lunak *open source*. Aplikasi ini dapat melakukan suatu tahapan *data mining* atau *data analytic* dengan konsep visual *programming* sehingga lebih mudah bagi peneliti yang tidak memiliki dasar pemrograman/IT.

Tahap analisis yang pertama adalah *Exploratory Data*, yaitu merupakan bagian statistika deskriptif guna mencari informasi umum seperti korelasi dan

Tabel 1. Variabel Penelitian

VARIABEL TARGET	
Y	Opini Audit LKKL
VARIABEL FEATURE (PREDICTOR)	
X₁	Aset
X₂	Anggaran
X₃	Realisasi
X₄	Jumlah DIPA
X₅	Pagu Minus
X₆	Kontrak
X₇	UP/TUP
X₈	LPJ
X₉	Penyerapan
X₁₀	TAG
X₁₁	SPM
X₁₂	Afiliasi Politik
X₁₃	Tk. Pendidikan Pim
X₁₄	Jenis Pendidikan Pim
X₁₅	Umur Lembaga
X₁₆	Fraud Kas
X₁₇	Fraud Non Kas
X₁₈	Deviasi SPM
X₁₉	Temuan SPI
X₂₀	Temuan UU
X₂₁	Tindak Lanjut SPI
X₂₂	Tindak Lanjut UU
X₂₃	Temuan (Gabungan)
X₂₄	Tindak Lanjut (Gabungan)

distribusi data guna menentukan variabel mana saja yang paling tepat digunakan sebagai *feature/predictor*.

Tahap analisis kedua adalah *Data Preparation*, yaitu mempersiapkan data yang akan di estimasi dalam permodelan. Pada tahap ini dilakukan pemilihan variabel berdasarkan tahapan sebelumnya salah satunya yaitu korelasi. Pada tahap ini korelasi antar variabel *feature/predictor* dipakai untuk menentukan multikolinearitas dalam

data, dimana menurut Gujarati (2007) korelasi dengan nilai di atas 0,8 terindikasi gejala multikolinearitas. Selain itu juga dilakukan pengisian atas *missing value* pada data yang bisa mengganggu hasil permodelan. Menurut Sarkodie & Owusu (2020), pengisian *missing value* pada Orange dapat dilakukan dengan lima teknik yaitu *Don't Impute* (tidak diisi), *Average/Most Frequent* (dengan rata-rata/ nilai yang sering muncul), *As a distinct value* (membuat nilai-nilai baru untuk menggantikan yang hilang), *Random Values* (pengisian acak oleh machine), dan *Remove Examples* (menghapus raw data yang kosong). Mempertimbangkan jenis pola data peneliti memilih teknik *Average/ Most Frequent* untuk mengatasi *missing values*.

Tahap analisis ketiga adalah *Modelling*, yaitu tahapan permodelan prediksi klasifikasi. Pada tahap ini digunakan Teknik random sampling dan pembagian dataset serta pengulangan pengujian data (*repeat train/test*).

Tahap analisis keempat adalah *Model evaluation*, yaitu untuk mengetahui kinerja dari masing-masing model klasifikasi dengan membandingkan test and score dari beberapa model yang digunakan untuk dipilih satu model terbaik, model terpilih kemudian disimpan dalam pickled models (pkl).

Tahap analisis kelima adalah *Deployment*, yaitu tahapan lebih lanjut yang bertujuan menggunakan model terpilih untuk simulasi prediksi. *Deployment* aplikasi simulasi dilakukan dengan menggunakan Streamlit. Simulasi dilakukan dengan mengisi asumsi atas variabel-variabel yang

mempengaruhi target sesuai kondisi kementerian negara/lembaga, kemudian akan dihubungkan dengan model terpilih (*pickled models*) yang menghasilkan prediksi Kualitas Laporan Keuangan suatu Kementerian negara/lembaga.


HASIL PENELITIAN DAN PEMBAHASAN

Sebagaimana dijelaskan pada bagian sebelumnya, proses pengolahan *data analytics* pada penelitian ini dilakukan dengan menggunakan aplikasi Orange. Gambaran proses pada aplikasi Orange sebagaimana pada Lampiran. Proses yang telah dilakukan meliputi beberapa tahapan yaitu *Exploratory Data*, *Data Preparation*, *Modelling* dan *Model Evaluation*.

Exploratory Data

Sesuai hasil olah data dengan menggunakan aplikasi Orange. Dilakukan eksplorasi terhadap hubungan antar variabel *feature/predictor*. Hal ini bertujuan untuk menghindarkan model dari adanya multikolinearitas yang dapat mengganggu akurasi model. Berdasarkan hasil korelasi sebagaimana pada gambar 2, diketahui bahwa

Gambar 2. Uji Korelasi



Sumber: Olah data Orange

terdapat variabel yang memiliki nilai korelasi di atas 0,8.

Dari hasil korelasi di atas peneliti memutuskan untuk mengeluarkan beberapa variabel yaitu Anggaran dan Temuan UU dikarenakan memiliki nilai korelasi di atas 0,8. Pada tahap ini peneliti membuat variabel baru yaitu penyerapan yang didapat dari Realisasi dibagi Anggaran melalui *feature constructor*.

Berdasarkan penelusuran *missing value* diketahui pada data terdapat 3,1% *missing* data yang dapat diketahui pada info Data Table di Orange. Setelah dilakukan penelusuran pada *dataset*, diketahui bahwa *missing value* tersebut banyak terdapat pada variabel temuan SPI dan tindak lanjut atas rekomendasi temuan SPI tahun 2020, hal ini karena pada tahun 2020 temuan SPI dan tindak lanjut atas rekomendasi temuan SPI pada LHP BPK digabung dengan temuan UU dan tindak lanjut atas rekomendasi temuan UU, sehingga peneliti membuat satu variabel baru yaitu temuan gabungan dan tindak lanjut atas rekomendasi temuan gabungan yang selanjutnya disebut tindak lanjut atas rekomendasi BPK, serta mengeluarkan variabel pembentuknya.

Selanjutnya dari distribusi data juga ditemukan adanya *imbalance class* pada data variabel target dimana Opini yang memiliki label WTP selama periode data dari 2018-2020 mendominasi sebesar 96% sedangkan Opini dengan label WDP dan TMP hanya sekitar 4% dari total data. Penanganan *imbalance class* ini akan dilakukan pada tahap *modelling*.

Data Preparation

Berdasarkan informasi yang diperoleh pada tahap *Exploratory Data*, pada tahap ini dilakukan pemilihan

variabel sebagai *feature/predictor* yang kemudian dijadikan dasar pembentukan dataset yang akan diproses/dijalankan. Variabel yang dikeluarkan antara lain variabel Anggaran, variabel Deviasi SPM, variabel Temuan UU, variabel Tindak Lanjut atas rekomendasi temuan UU, variabel temuan SPI, dan variabel tindak lanjut atas rekomendasi temuan SPI. Hal ini perlu dilakukan oleh peneliti untuk mendukung proses permodelan dan menghindari hasil yang bias. Pada tahap ini juga dilakukan penginputan *missing value* (data kosong) dengan memilih metode *average/most frequent*, dengan demikian diharapkan estimasi model dapat optimal.

Modelling

Permodelan *machine learning* pada penelitian ini dilakukan terhadap beberapa model untuk prediksi klasifikasi yaitu *Decision Tree*, *Random Forrest*, *Support Vector Machine*, dan *Naïve Baiyes*. Kemudian proses *sampling* untuk *learner model* menggunakan teknik *Random Sampling* yaitu teknik membagi data secara acak ke dalam data *Train* dan data *Test* dengan proporsi tertentu (misalnya 70:30), kemudian seluruh prosedur diulang untuk beberapa kali tertentu dan dapat dilakukan secara *stratified*. Pada penelitian ini dilakukan dengan pengulangan atau *Repeat Train/Test* sebanyak 20 kali dan pembagian data *Train* dan data *Test* sebesar 70:30. Teknik *Random Sampling* tersebut dilakukan juga secara bertingkat (*Stratified*) untuk mengatasi permasalahan *imbalance class* sehingga mendapatkan hasil maksimal.

Model Evaluation

Selanjutnya Evaluasi model klasifikasi difokuskan terhadap

Classification Accuracy yang merupakan proporsi hasil estimasi yang diklasifikasikan dengan benar, dan *F1 Score* merupakan *harmonic mean* tertimbang dari nilai *precision* dan nilai *recall*. Mengingat bahwa jumlah non-WTP jumlahnya sedikit (*imbalance class*), maka dalam menentukan model terpilih peneliti menekankan juga proporsi *true* negatif di antara semua estimasi negatif, misal jumlah yang tidak sakit di antara semua yang didiagnosis tidak sakit. Hal ini penting mengingat penelitian ini bertujuan untuk mitigasi resiko penurunan Kualitas LK. Jadi peneliti sangat memperhatikan hasil prediksi untuk kategori WDP dan TMP. Adapun hasil *test and score* atau evaluasi dari permodelan dijelaskan pada Gambar 3.

Berdasarkan hasil evaluasi model terlihat SVM memiliki nilai Akurasi Klasifikasi (CA) dan F1 yang lebih baik dibandingkan tiga model lainnya yaitu *Tree*, *Random Forest* dan *Naive Baiyes*. Selanjutnya untuk melihat lebih detail dan berfokus pada WDP dan TMP sebagai bagian penanganan *imbalance class* serta dikarenakan penelitian ini fokus terhadap mitigasi resiko dilakukan

analisis ROC. Menurut Kusmantoro (2018) analisis ROC banyak dipakai dalam menggambarkan keakuratan diagnostik. Sehingga untuk menambah keyakinan model terbaik hasil dari evaluasi model dengan *test and score* juga dilakukan analisis ROC untuk masing-masing kelas WTP, WDP dan TMP. Keakuratan prediksi dalam analisis ini dapat diketahui dari area di bawah kurva ROC masing-masing model yang digunakan. Dengan demikian akan dapat terlihat hasil prediksi untuk masing-masing kelas. Adapun hasil analisis ROC pada penelitian ini dengan hasil sebagaimana pada gambar 4.

Terlihat bahwa garis SVM pada ROC analysis lebih baik yang selalu berada paling atas mendekati angka 1. Bahkan untuk kategori WDP dan TMP yang jumlah datanya sedikit, model SVM lebih baik dibandingkan model yang lain.

Variabel paling berpengaruh

Selain mendapat model yang paling baik dalam memprediksi klasifikasi kualitas LKKL, perlu juga di ketahui variabel-variabel mana saja yang

Gambar 3. *Evaluasi Model*

Model	AUC	CA	F1	Precision	Recall
Tree	0.599	0.927	0.934	0.941	0.927
SVM	0.794	0.961	0.942	0.924	0.961
Random Forest	0.713	0.960	0.942	0.924	0.960
Naive Bayes	0.741	0.013	0.000	0.000	0.013

	Tree	SVM	Random ...	Naive Ba...
Tree				
SVM				
Random Forest				
Naive Bayes				

Table shows probabilities that the score for the model in the row is higher than that of the model in the column. Small numbers show the probability that the difference is negligible.


Sumber: Olah data Orange

paling berpengaruh terhadap kualitas LKKL. Hal ini dapat dimanfaatkan dalam mitigasi resiko atas target Kualitas LKKL dan fokus pembinaan Akuntansi Kementerian Lembaga. Aplikasi Orange juga dilengkapi dengan beberapa *tools* untuk mencari variabel yang berpengaruh dari dataset yang digunakan. Berikut beberapa *tools* yang dipilih peneliti dalam mengetahui

Variabel yang berpengaruh terhadap Kualitas Laporan Keuangan K/L.

Berdasarkan Tabel *Decrease Gini* (gambar 5) dan *FreeViz* (gambar 6) diketahui bahwa lima variabel yang paling berpengaruh yaitu *Fraud* Kas, Temuan (gabungan), Tindak Lanjut atas Rekomendasi BPK, UP/TUP serta Realisasi. *Fraud* Kas yang lebih condong pada tindakan korupsi memang relatif berdampak pada citra lembaga maupun


Gambar 4. ROC Analysis



Sumber: Olah data Orange

opini auditnya, sebagaimana penelitian Rini & Sarah (2014) yang menemukan keterkaitan kuat antara korupsi dengan opini yang diberikan oleh BPK RI. Terkait temuan dan tindak lanjut atas rekomendasi BPK yang juga menjadi variabel paling berpengaruh dalam penelitian ini sejalan dengan temuan Sari et al. (2015) yaitu temuan audit, tindak lanjut hasil pemeriksaan berpengaruh terhadap opini audit secara tidak langsung. Berikutnya ada variabel UP/TUP dimana seringkali pelanggaran atas ketentuan UP/TUP terutama siklus *revolving*, Armin (2018) menemukan bahwa dalam siklus UP/TUP masih sering terdapat kesalahan administrasi yang tidak dapat dihindari. Selanjutnya terkait realisasi, yang mana hal tersebut tertuang dalam Laporan Realisasi Anggaran dan menjadi salah satu bahan utama audit BPK. Selain itu Realisasi juga menjadi cerminan kinerja keuangan lembaga. Kesalahan penyajian

Gambar 5. Mean Decrease Gini




Sumber: Olah data Orange

dan kewajaran dalam Laporan Realisasi bisa menjadi fatal bagi temuan audit yang dapat mempengaruhi opini audit.

Deployment

Model terbaik yang diperoleh dari hasil model evaluation selanjutnya di

Gambar 6. FreeViz



Sumber: Olah Data Orange

simpan dalam file pickle (.pkl) dan digunakan untuk simulasi prediksi pada Aplikasi Streamlit. Pada simulasi ini dapat dimasukkan estimasi nilai variabel *predictor/feature* sesuai kondisi terupdate yang ada pada Kementerian Lembaga yang kemudian dapat dilakukan “klik prediksi” untuk mendapatkan perkiraan Prediksi Kualitas Laporan Keuangan. Setelah diketahui prediksinya maka dapat ditindaklanjuti dengan langkah-langkah yang akan dilakukan dalam proses pembianan Laporan Keuangan pada Kementerian/Lembaga terkait. Adapun ilustrasi tampilan simulasi pada Streamlit sebagaimana pada gambar 7.


KESIMPULAN DAN SARAN

Berdasarkan hasil pengujian dan pemrosesan melalui teknik *machine learning*, ditemukan bahwa variabel *fraud* kas, temuan (gabungan), tindak lanjut rekomendasi BPK atas temuan (gabungan), UP/TUP, dan realisasi mempunyai pengaruh yang kuat terhadap kualitas laporan keuangan kementerian negara/lembaga. Berdasarkan variabel-variabel tersebut,

maka dalam peningkatan kualitas LKKL, pemerintah pusat dapat memfokuskan pada bidang pencegahan atau deteksi dini kemungkinan terjadinya *fraud*. Selain itu agar setiap tindak lanjut atas rekomendasi BPK hendaknya menjadi prioritas dalam setiap pengambilan kebijakan.

Dari beberapa model yang dilakukan pengujian, didapatkan bahwa model *Support Vector Machine* (SVM) mampu membuat prediksi klasifikasi yang lebih baik dengan akurasi 96,1%. Model SVM ini dapat dijadikan *tools* sebagai *early warning system* dalam manajemen pengelolaan akuntansi pemerintahan khususnya kepada Kementerian negara/lembaga sekaligus mendukung pengambilan kebijakan baik di Kementerian Keuangan selaku *lead* kebijakan akuntansi pemerintah pusat maupun kementerian negara/lembaga selaku penyusun laporan keuangan. Melalui temuan dan model di atas, diharapkan mampu memberikan rekomendasi dari mitigasi risiko dalam pembinaan akuntansi pemerintah pusat.

Gambar 7. Ilustrasi Streamlit



Sumber: Streamlit (local host)

IMPLIKASI DAN KETERBATASAN

Hasil penelitian ini diharapkan menjadi salah satu terobosan dalam pengelolaan keuangan negara khususnya bidang pelaporan dan pertanggungjawaban atas pelaksanaan anggaran untuk meningkatkan fungsi analisis dalam akuntansi sehingga memudahkan mitigasi resiko atas keberlangsungan akuntabilitas pemerintah pusat. Penelitian ini memiliki beberapa keterbatasan, seperti penggunaan data di dalam penelitian merupakan data sekunder dalam tiga tahun dan proses pengujian model menggunakan aplikasi *orange*. Tahapan *Deployment* pada paper ini juga masih perlu penyempurnaan dalam penyajian dan aliran data yang lebih dinamis.

Oleh karenanya, dalam penelitian selanjutnya diharapkan dapat menggunakan *mixed method*, yakni menggabungkan antara data sekunder dengan wawancara untuk memperdalam analisis mengenai faktor-faktor yang berpengaruh terhadap kualitas LKKL. Selain itu, untuk mendapatkan hasil yang akurat, penelitian yang akan datang dapat melakukan pemrosesan melalui *machine learning* menggunakan *python* sekaligus menambah data pengamatan tahunan sebelumnya guna mengurangi *imbalance class*.

REFERENSI

- Agustina, W., Furqon, M. T., & Rahayudi, B. (2018). Implementasi Metode Support Vector Machine (SVM) Untuk Klasifikasi Rumah Layak Huni (Studi Kasus: Desa Kidal Kecamatan Tumpang Kabupaten Malang). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 2(10), 3366-3372.
- Annur, H. (2018). Klasifikasi Masyarakat Miskin Menggunakan Metode Naive Bayes. *ILKOM Jurnal Ilmiah*, 10(2), 160-165.
- Armin, K. (2018). Analisis Siklus Pengeluaran Uang Persediaan (UP) pada Kantor Pengawasan Dan Pelayanan Bea dan Cukai TMP B Palembang. *Jurnal Kompetitif*, 7(2).
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Cheng, R. H. (1992). An Empirical Analysis of Theories on Factors Influencing State Government Accounting Disclosure. *Journal of Accounting and Public Policy*, 11(1), 1-42.
- Dhawangkhar, M. (2017). Prediksi Intensitas Hujan Kota Surabaya dengan Matlab menggunakan Teknik Random Forest dan CART (Studi Kasus Kota Surabaya). *Tugas Akhir*. Institut Teknologi Sepuluh Nopember.
- Didi, D., & Kusuma, I. C. (2018). Faktor-Faktor yang Berpengaruh terhadap Kecenderungan Kecurangan (Fraud): Persepsi Pegawai Pemerintahan Daerah Kota Bogor. *Jurnal Akuntansi dan Keuangan Indonesia*, 15(1), 1-20.
- Fathurrahman, F., & Putra, Y. K. (2021). Analisis Perbandingan Pengaruh Pertumbuhan Ekonomi Terhadap Tingkat Kesejahteraan Masyarakat Pada Desa Suralaga Dengan Menggunakan Algoritma Naive Bayes Dan Support Vector Machine (Svm). *Infotek: Jurnal Informatika dan Teknologi*, 4(1), 1-10.

- Fatimah, D., Sari R. N., & Rasuli, M. (2014). Pengaruh Sistem Pengendalian Intern, Kepatuhan terhadap Peraturan Perundang-Undangan, Opini Audit Tahun Sebelumnya dan Umur Pemerintah Daerah terhadap Penerimaan Opini Wajar Tanpa Pengecualian Pada Laporan Keuangan Pemerintah Daerah di Seluruh Indonesia. *Jurnal Akuntansi*, 3 (1): 1-15.
- Gujarati, D. N. (2007). Dasar-dasar Ekonometrika.
- Jensen, M. C., & Meckling, W. H. (1976). Theory of The Firm: Managerial Behavior, Agency Costs and Ownership Structure. *Journal of Financial Economics*, 3(4), 305-360.
- Badan Pemeriksa Keuangan. (2012). Keputusan Badan Pemeriksa Keuangan Republik Indonesia Nomor 4/K/I-XIII.2/9/2012 tentang Buletin Teknis Nomor 01 Pelaporan Hasil Pemeriksaan Atas Laporan Keuangan Pemerintah.
- Kewo, C. L., & Afiah, N. N. (2017). Does quality of financial statement affected by internal control system and internal audit?. *International Journal of Economics and Financial Issues*, 7(2), 568-573.
- Kusmantoro, Z. N. (2018). Akurasi Uji Diagnostik Menggunakan Luasan Bawah Kurva ROC Smoothed Empirical (*Doctoral dissertation, Universitas Gadjah Mada*).
- Lewis, R. J. (2000). An Introduction to Classification and Regression Tree (CART). In *Annual meeting of the society for academic emergency medicine in San Francisco, California* (Vol. 14). Citeseer.
- Munawar, N., & Abdullah, S. (2016). Pengaruh jumlah temuan audit atas SPI dan jumlah temuan audit atas kepatuhan terhadap opini atas laporan keuangan Pemerintah kabupaten/kota di Aceh. *Jurnal Administrasi Akuntansi: Program Pascasarjana Unsyiah*, 5(2).
- Nuraeni. (2014). The Impact of Local Governments Characteristics to Audit Quality Indonesia Perspectives. *Finance and Banking Journal*, 16(1), 66-82.
- Nurdiono, N., Sugiri, S., & Halim, A., Gudono, G. (2016). The Effect of Budgets' Proportion and Non-Financial Factors on The Audit Results of Local Governments' Financial Statements in Indonesia. *Journal of Indonesian Economy and Business*, 31(2), 178-191.
- Oktaviani, P.A., Wulandari, Y., & Ispriyanti, D. (2014). Penerapan Metode Klasifikasi Support Vector Machine (SVM) pada Data Akreditasi Sekolah Dasar (SD) di Kabupaten Magelang. *Gaussian*.
- Peraturan Direktur Jenderal Perbendaharaan Nomor PER-4/PB/2021 tentang Petunjuk Teknis Penilaian Indikator Kinerja Pelaksanaan Anggaran Belanja Kementerian negara/lembaga.
- Peraturan Menteri Keuangan Nomor 215/PMK.05/2016 Perubahan atas Peraturan Menteri Keuangan Nomor 213/PMK.05/2013 Tentang tentang Sistem Akuntansi dan Pelaporan Keuangan Pemerintah Pusat.
- Primajaya, A., & Sari, B. N. (2018). Random Forest Algorithm for Prediction of Precipitation. *Indonesian Journal of Artificial*

- Intelligence and Data Mining*, 1(1), 27-31.
- Rini, R., & Sarah, A. (2014). Opini audit dan pengungkapan atas laporan keuangan pemerintah kabupaten serta kaitannya dengan korupsi di Indonesia. *Etikonomi*, 13(1).
- Roni, M., Husnan, L. H., & Fitriah, N. (2019). Determinan Kualitas Laporan Keuangan Satuan Kerja di Wilayah Pembayaran Kantor Pelayanan Perbendaharaan Negara Mataram. *Jurnal Akuntansi Aktual*, 3(2), 175-187.
- Sanjaya, J., Renata, E., & Budiman, V. E., Anderson, F., & Ayub, M. (2020). Prediksi Kelalaian Pinjaman Bank Menggunakan Random Forest dan Adaptive Boosting. *Jurnal Teknik Informatika Dan Sistem Informasi*, 6(1).
- Sari, A. P. (2016). Faktor-Faktor yang Mempengaruhi Opini Audit dengan Tingkat Pengungkapan Laporan Keuangan Kementerian/Lembaga sebagai Variabel Intervening. *Jurnal BPPK: Badan Pendidikan dan Pelatihan Keuangan*, 9(1), 33-46.
- Sari, A. P., Martani, D., & Setyaningrum, D. (2015). Pengaruh temuan audit, tindak lanjut hasil pemeriksaan dan kualitas sumber daya manusia terhadap opini audit melalui tingkat pengungkapan laporan keuangan kementerian/lembaga. *Simposium Nasional Akuntansi XVIII*.
- Sarkodie, S. A., & Owusu, P. A. (2020). How to apply dynamic panel bootstrap-corrected fixed-effects (xtbcsfe) and heterogeneous dynamics (panelhetero). *MethodsX*, 7, 101045.
- Setiadi, B. (2015). Penerapan Algoritma Decision Tree C4.5 Untuk Penilaian Rumah Tunggal. *Info Teknik*. 16(2), 195-206.
- Setyanto, E., & Ritchi, H. (2018). Faktor-faktor yang mempengaruhi akuntabilitas keuangan pemerintah daerah (Survey atas Kompetensi Aparatur, Kualitas Software SIA Penerapan SPI dan Penerapan SAP pada Pemerintah Daerah Kota dan Kabupaten di Provinsi Jawa Barat). *AKURAT| Jurnal Ilmiah Akuntansi FE UNIBBA*, 9(1), 89-105.
- Simanungkalit, A. (2015). Analisis Determinan Kualitas Laporan Keuangan Kementerian/Lembaga Satuan Kerja di Wilayah Kerja Kantor Pelayanan Perbendaharaan Negara Banda Aceh. *Thesis*. Universitas Sumatera Utara.
- Purnama, P., & Supriyanto, C. (2013). Deteksi Penyakit Diabetes Tipe II dengan Naïve Bayes Berbasis Particle Swarm Optimization. *Jurnal Teknologi Informasi*, 9(2).
- Surniandari, A., Rachmi, H., & Widiastuti, L. (2022). Klasifikasi Penduduk Dengan Tingkat Ekonomi Rendah Menggunakan Metode Klasifikasi Naïve Bayes. *Jurnal Ilmu Komputer dan Sistem Informasi*, 5(1), 34-40.
- Sutaryo, Naviantia, I. A., & Muhtar. (2020). Audit Opinion on Government Financial Report: Evidence from Local Government in Indonesia. *International Journal of Economics and Management*. 14 (1): 129-144.
- Ustuner, M., Samli, F. B., & Dixon, B. (2015). Application of Support Vector Machines for Landuse Classification Using High-Resolution RapidEye Images: A

- Sensitivity Analysis. *European Journal of Remote Sensing*.
- Windarsih, D. (2015). Hubungan Kualitas Reviu Laporan Keuangan Dengan Temuan Pemeriksaan BPK pada Pemerintah Kabupaten/Kota se-DIY. *Thesis*. Universitas Gadjah Mada.
- Yusuf W. Y. (2007). Perbandingan Performansi Algoritma Decision Tree C5.0, CART, dan CHAID: Kasus Prediksi Status Resiko Kredit di Bank X. *Seminar Nasional Aplikasi Teknologi Informasi 2007 (SNATI 2007)*
- Zimmerman, J. L. (1977). The Municipal Accounting Maze: An analysis of Political Incentives. *Journal of accounting research*, 107-144.