



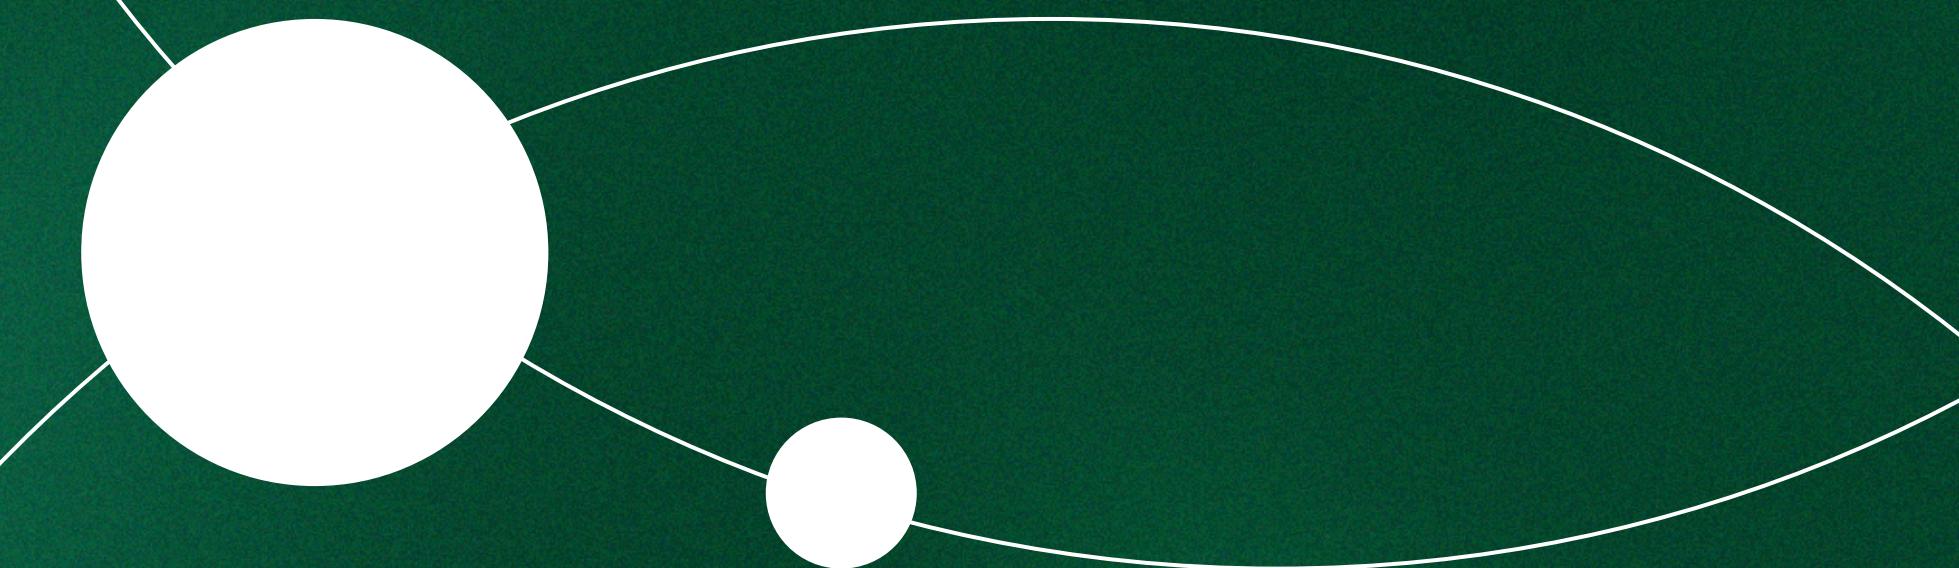
Presented by: Jakub Krawczyk Opejeka sp. z o.o.

5 years of production experience in using AI for ALS data classification

ת ויע ורע רענ הערל וו ו גיש פש והיילך ק ופ ו גיש פלאז"י" פצ זה ה דזוע ילה ש ופרק ה לשר א ש ה צחכ ר
ק ופ"ה ה טפכט ש:טודו לש יי סה א

וַיְפָתַח | תִּיכְלַשׁ | לְשֵׁבֶת | בְּשִׁבְטָה | לְפָקַד

- Traditional Challenges
 - Problems with macro-based classification
- AI Solution Architecture
 - Our neural network approach
- Production Implementation
 - Integration with existing workflows
- Measurable Results
 - Impact on performance
- Current Limitations
 - Honest assessment of challenges
- Future Development
 - Next generation improvements



Traditional Classification Challenges

הַבָּאֵן קְנָתָן כְּלֹתֶן וְרִתְמָה בְּמִזְרָחָה

- Increasing noise levels in LiDAR data that macros couldn't handle
- Complex terrain (crops on fields , mountainous areas, canyons, rocky surfaces)
- Urban environments with dense object clusters

Operational and Quality Issues:

- High manual labor requirements
- Objects requiring complete manual classification
- Inconsistent results due to tile - by - tile parameter adjustments and local variations
- Need for scalable solution to handle growing data volumes while controlling costs



- Transformation of the point cloud into a multi-layer raster with XYZ coordinates as attributes
- 64 by 64 by 64 by 3 arrays representing the point cloud are fed into 3D CNN
- Architecture inspired by encoder-decoder model
- Lossless reverse transformation to the point cloud
- Class prediction for each point as a result

Our ML Solution

הו צבאותם אפל, לא נאלה שטוף ע"פ



LiDAR CLASSIFICATION

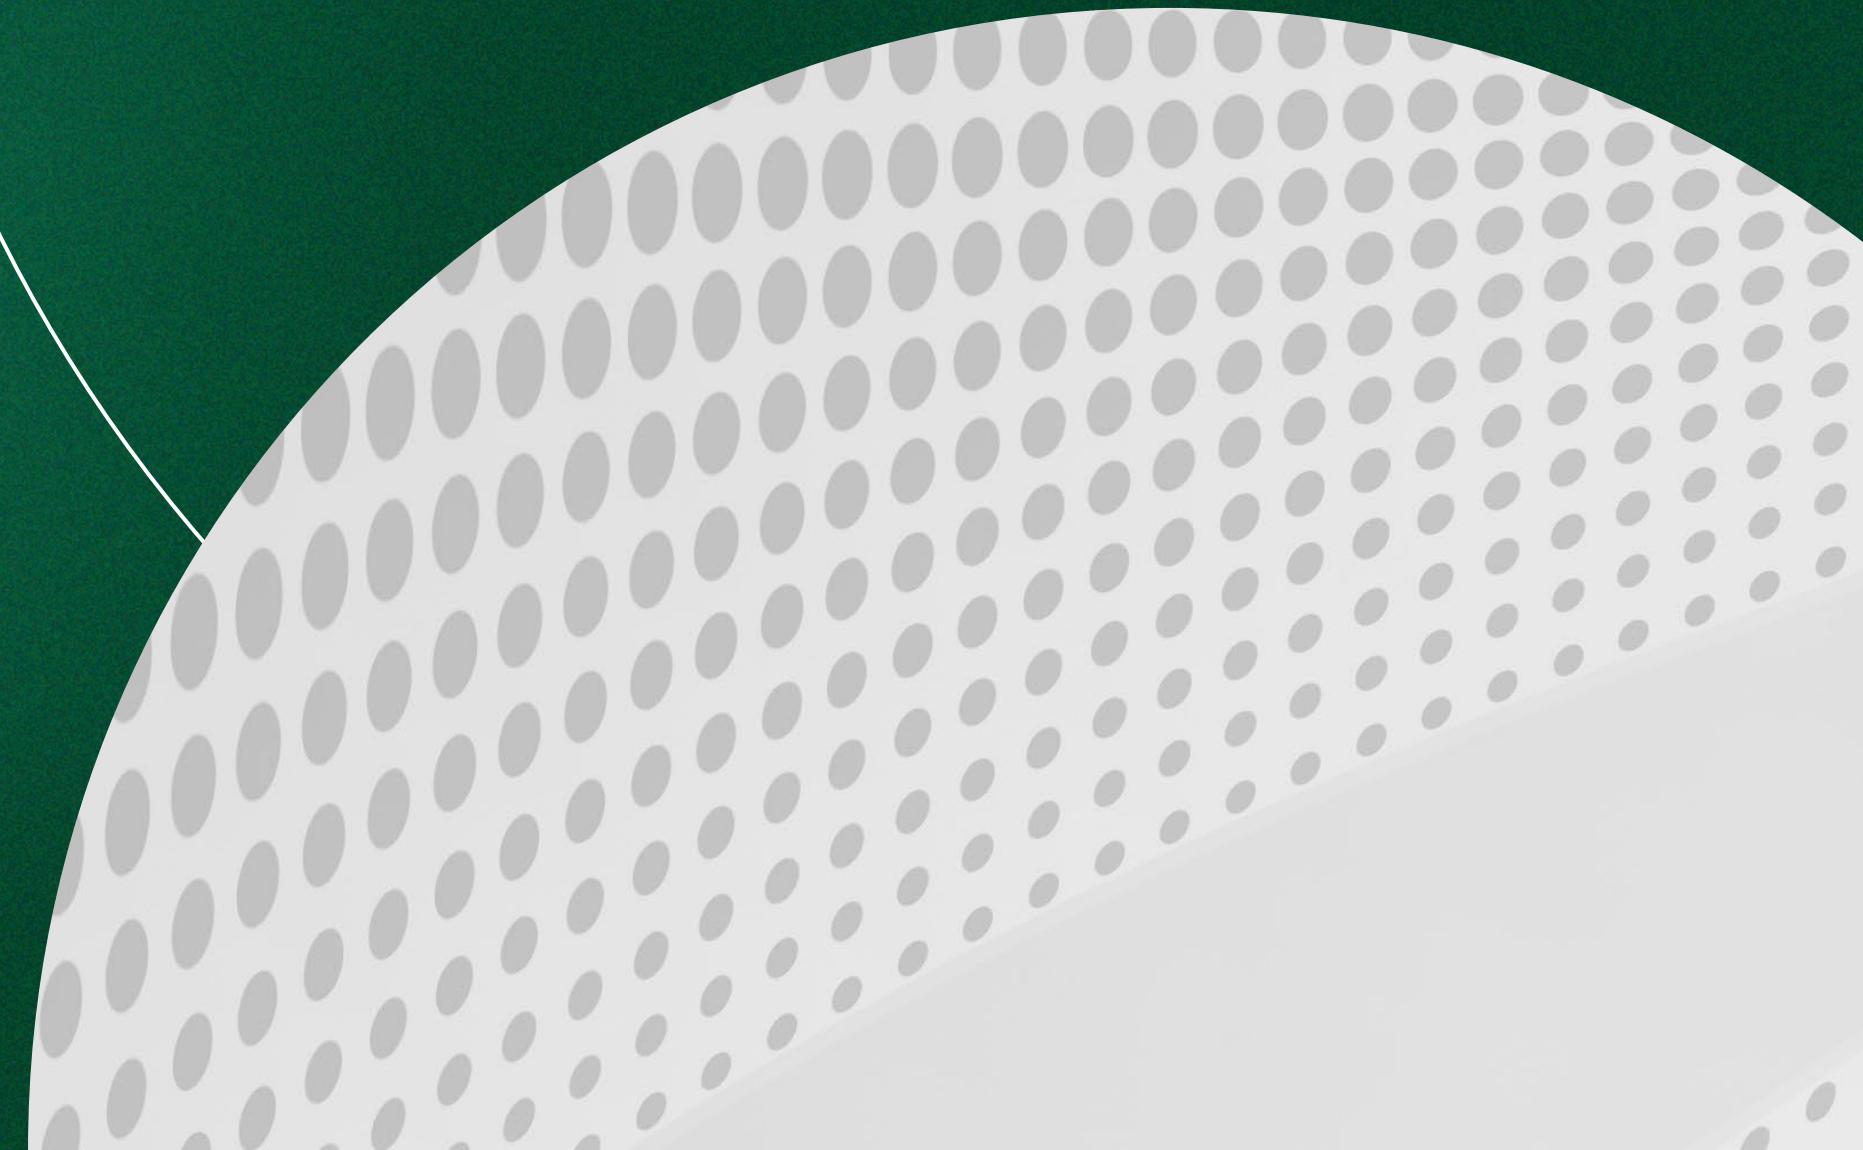
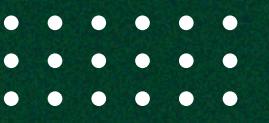
ASSISTED BY DEEP LEARNING



Production implementation

Biggest challenge?

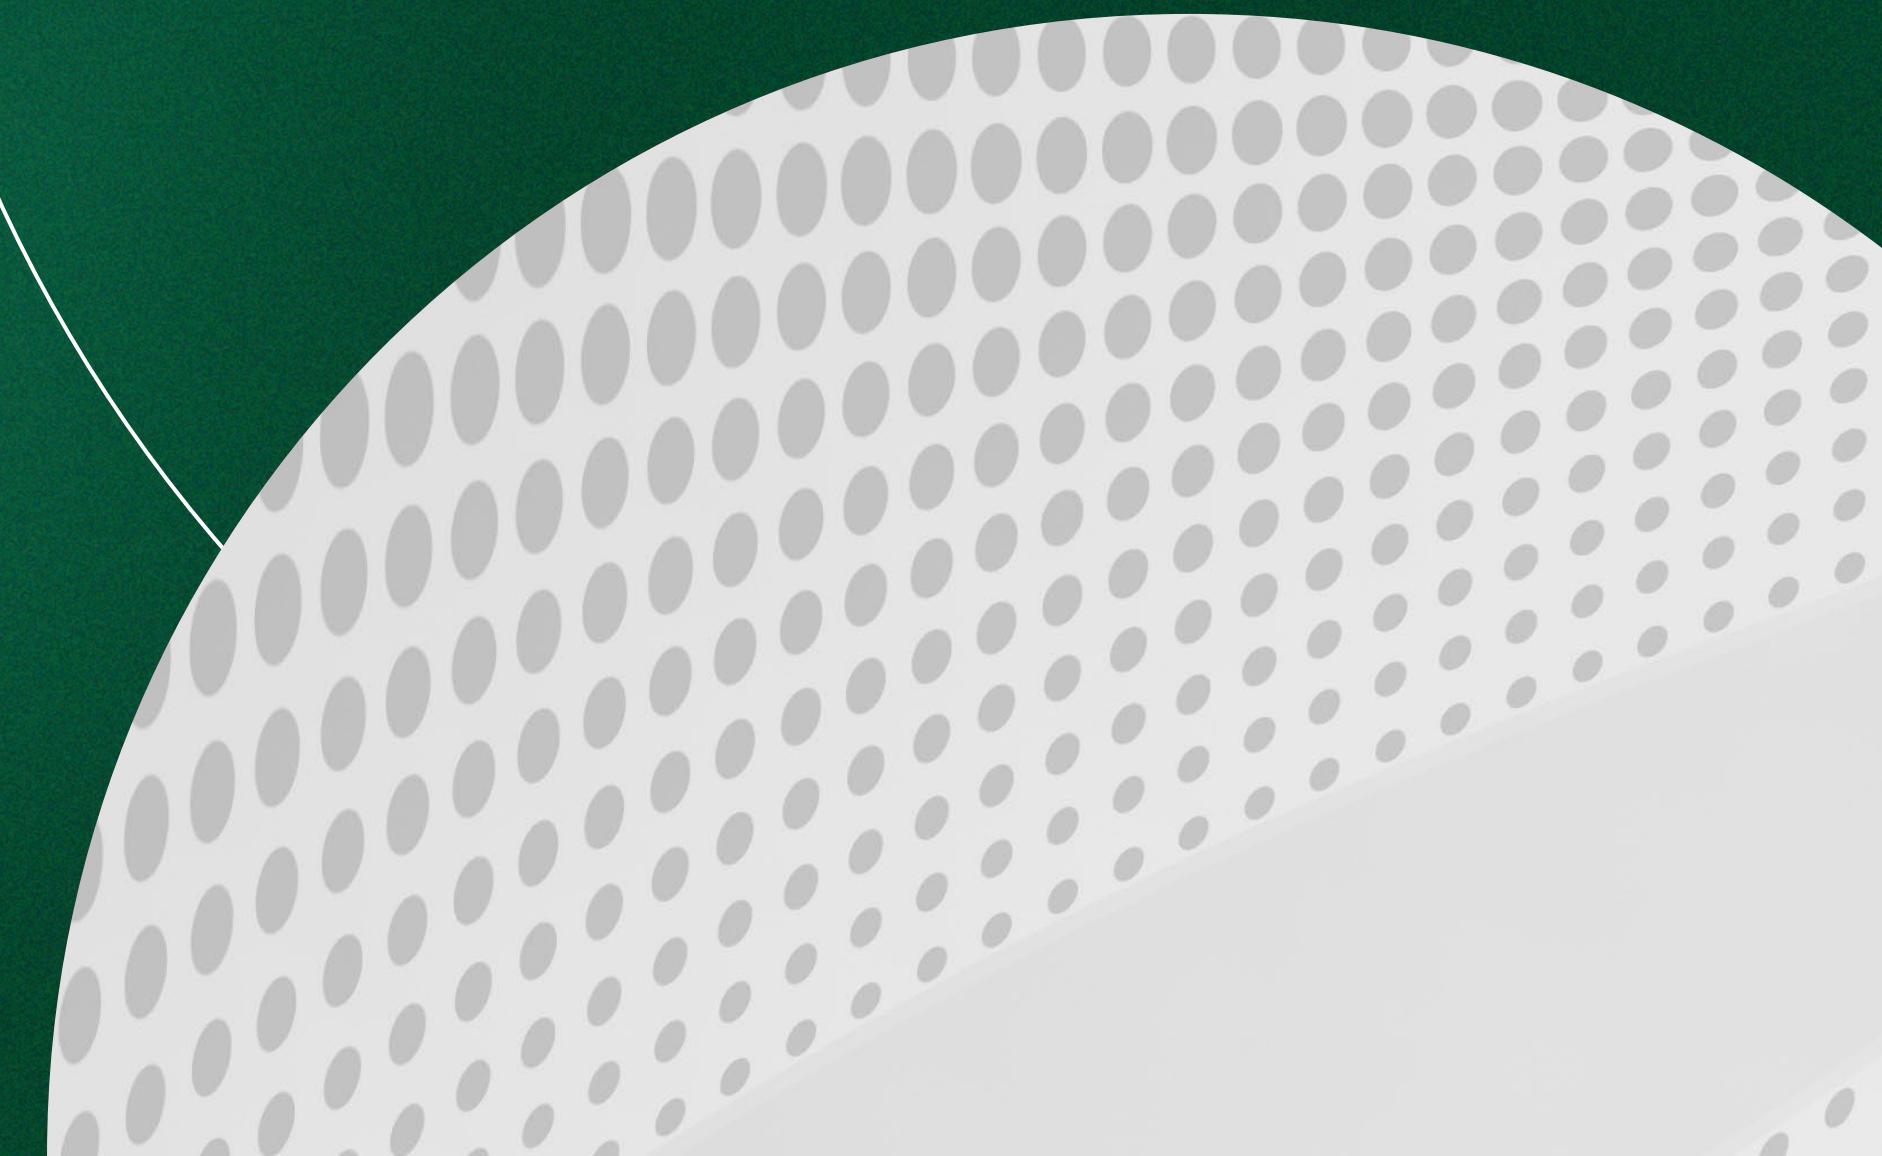
Convince the technicians
to start working with new
types of errors and different
approach.



Production implementation



מ ס ו שְׁמַנְיָה צְבָת שׁ בְּשִׂמְחָה כְּרָתֶל אֲלֵי שָׁמֶן



Quality Enhancements

- ✓ Building classification accuracy: 99.9% after prediction
- ✓ Consistent results across different terrain types
Predictable and uniform results regardless of local conditions
- ✓ Reduced dependency on specialized macro parameter tuning
- ✓ More km² processed annually with same human resources

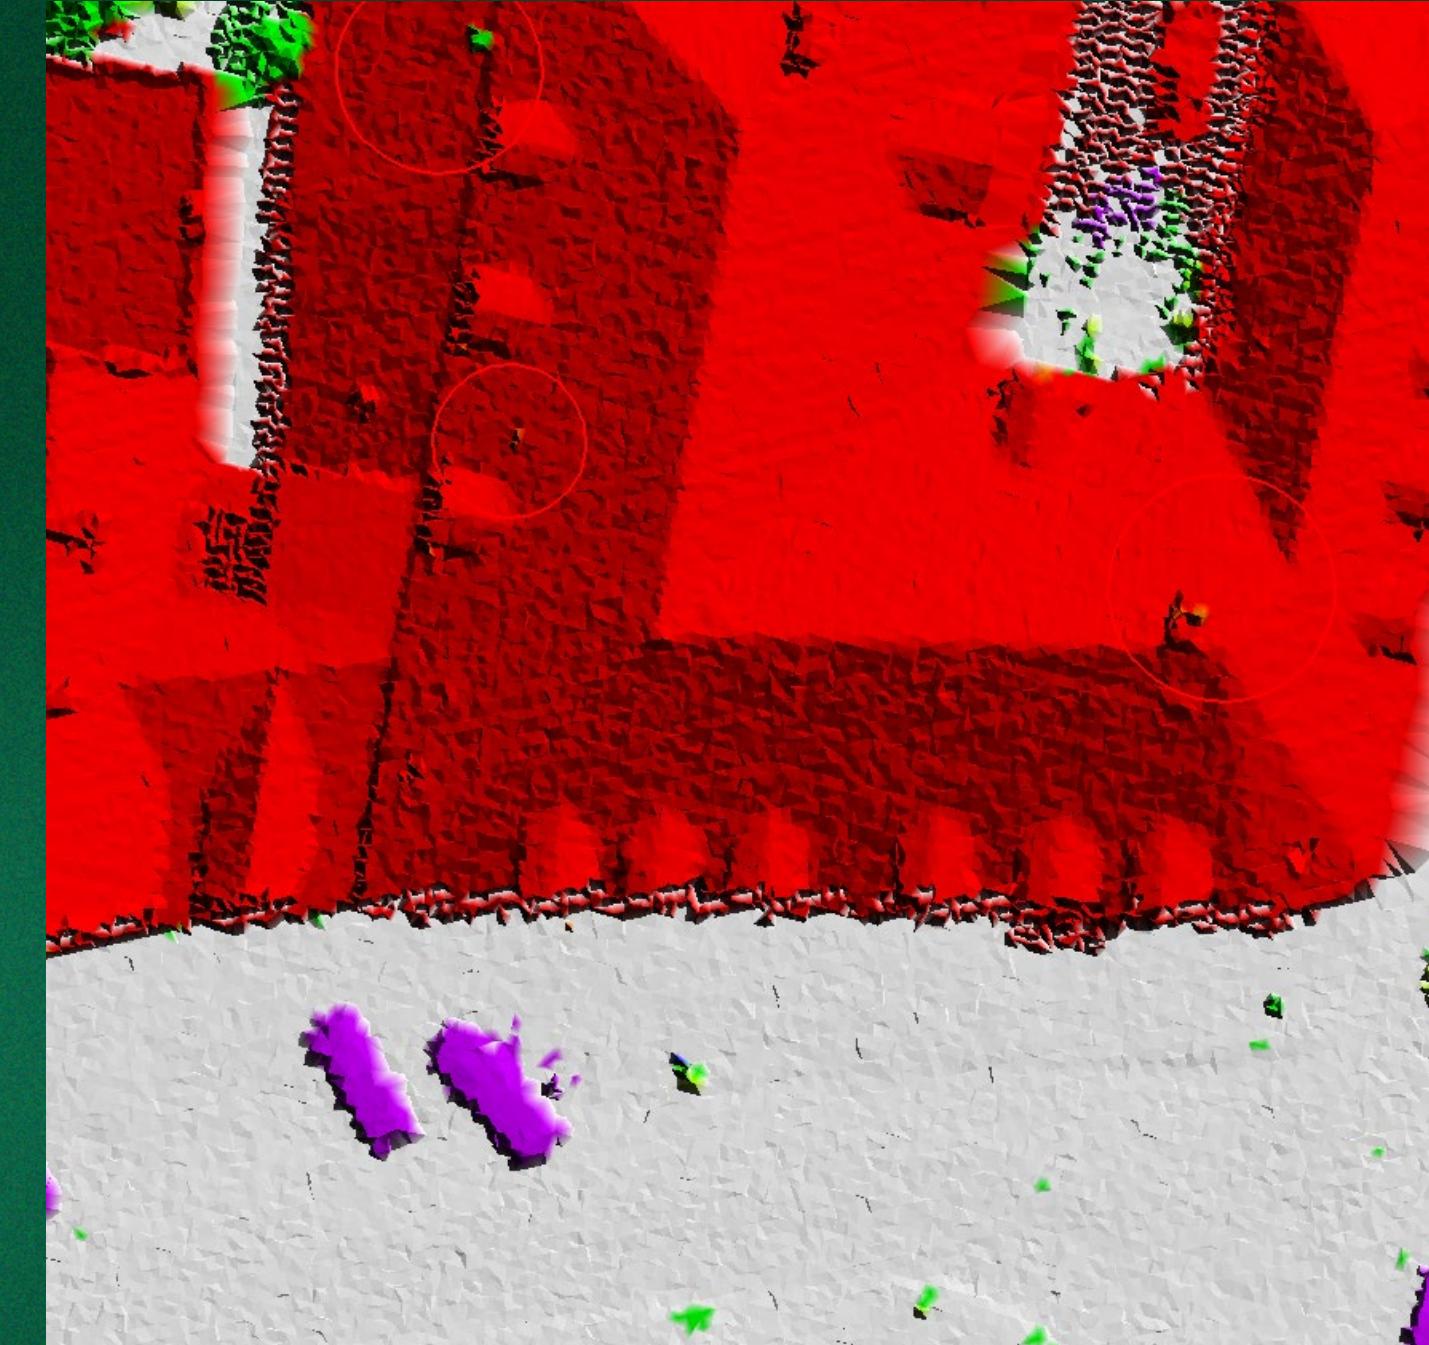
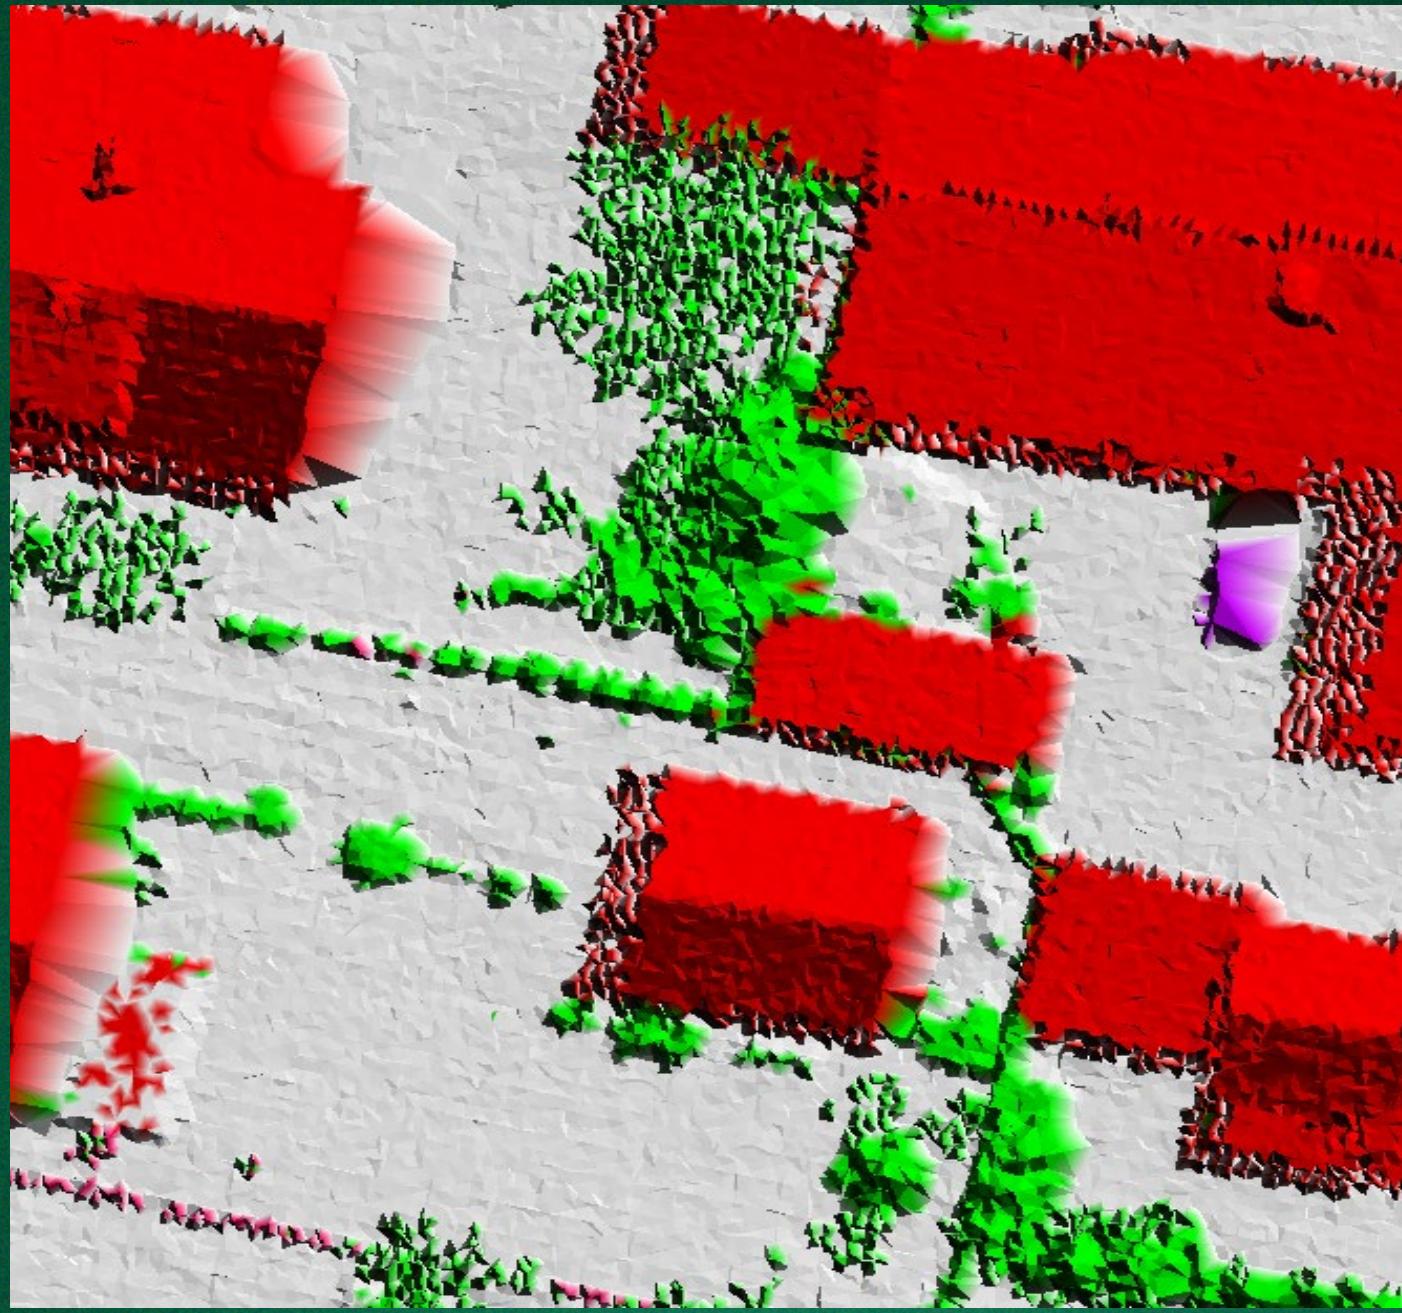
תֵּזֶבַע | תֵּזֶבַע | תֵּזֶבַע

- ✓ Productivity Improvements:
50% reduction in manual classification workload
- ✓ Daily throughput increase:
8 tiles → 13-16 tiles (up to 100% improvement)

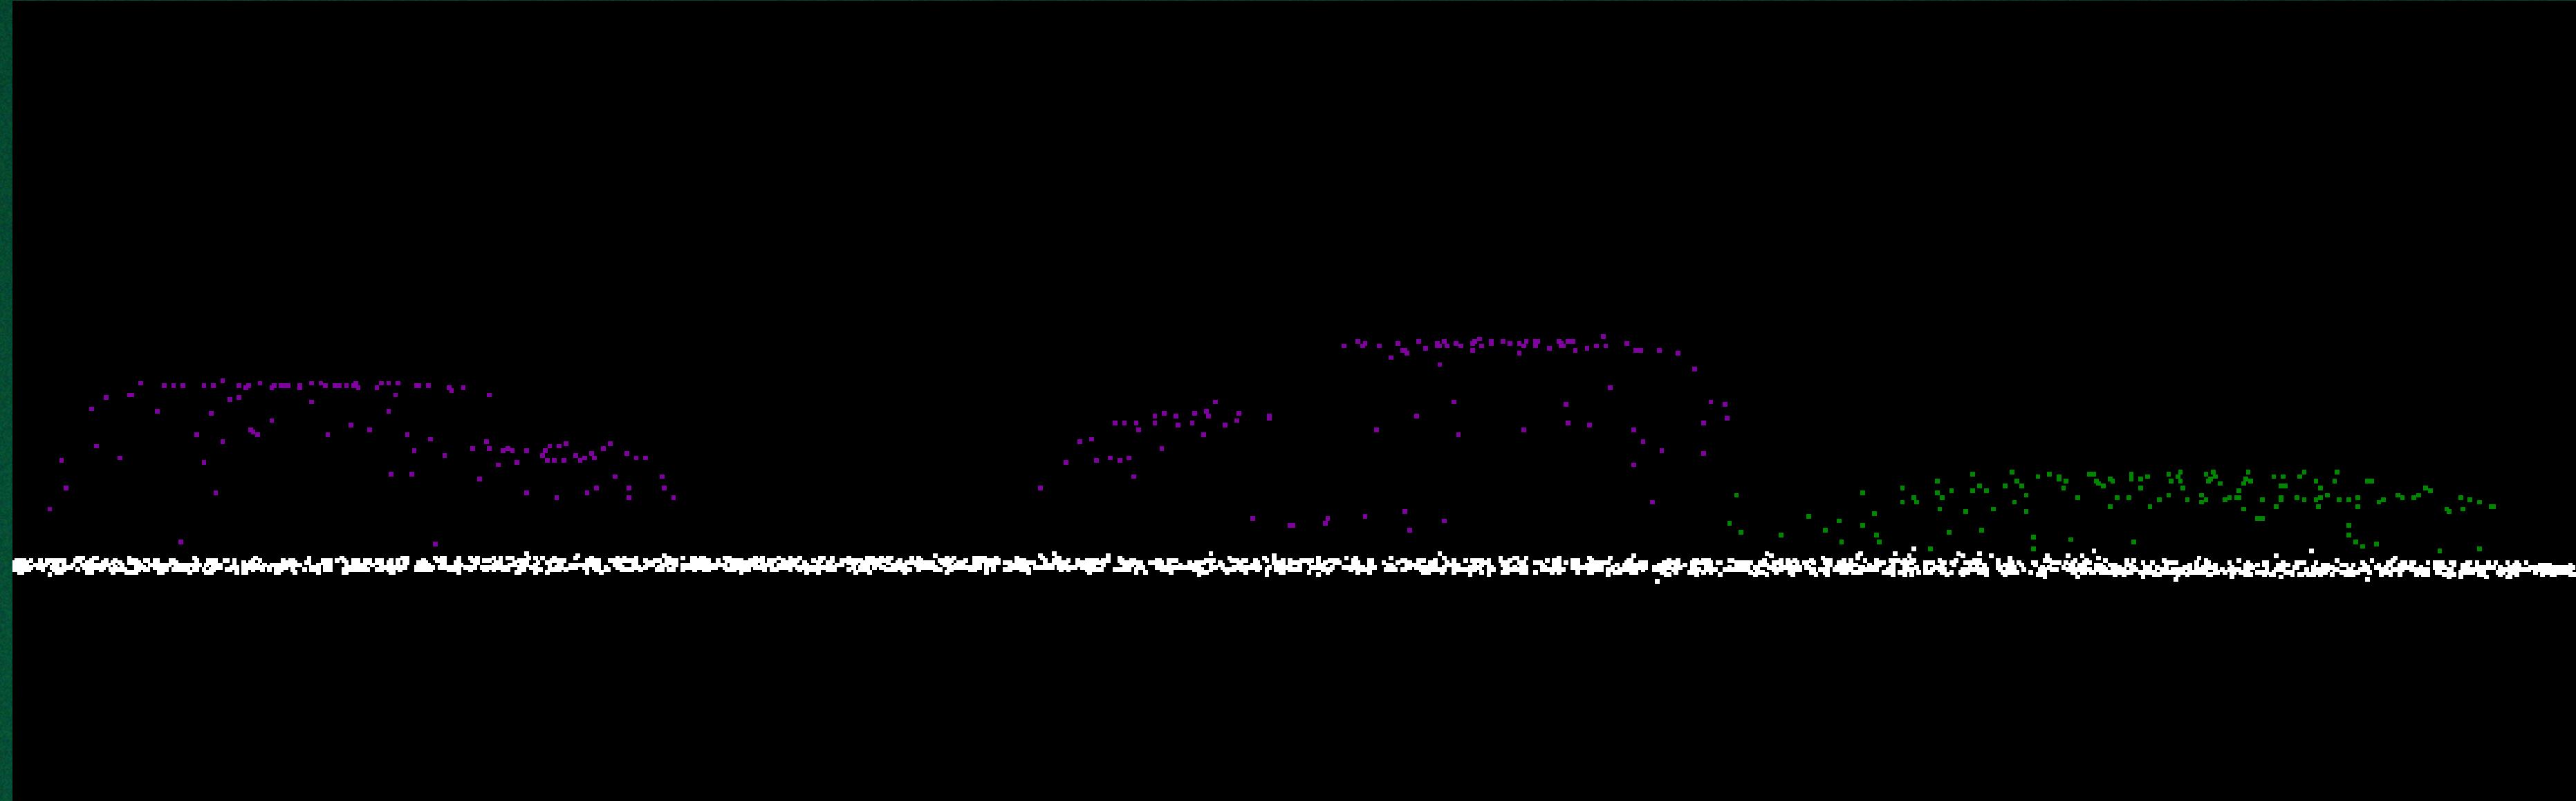
כ | אָשָׁלְמָן תְּאַתֵּן אָשָׁלְמָן



Small errors matter



כָּלְאָטָר פֶּתַחַת לִקְהָטָר



Future Development - Next generation improvements

✓ משקאות לאש לפ' לכ' ולל' כ | אקו צאשנתק כ לדשט טשר

כליאו ט רקיל אקליאו | רגשכ | פכתאיל רשקואט רכאמישטנא כלדשט זכפ
שיקואט ביליכ' ו נטפושה קואט לבקטואט ופ' כלז'ה ו זי
כקכ לאש כ | אקו שטאנט ו שיקוא | יטנאך כאשנתק ומית שיקוא אש לפ' לכ' ולכ' לא לזר

✓ מ, נט לאשנתק צ שיקואט פטנט צ כלז'ה ו זי

לדש לכ' לסטתק שיקואט פטנט נטנאט פטנט אפטתק כ לדשט טשר

✓ משקאות בלאשי לא | יטנא פ כלכש לא זר

כלא | אנטאט רכאמיל זט עטאלל זר: ג' אפטש לאטמאן א כשת, לזר
אנט ו ק' לדשט רכאמיל זט עטאלל זר: ג' תספ' פ' פ' זר ק' טר

✓ שיקוא | יטנאך כקטש לא זלכאמאש ל ר זוקל זלכוייש ת

Production implementation



על גש לקט דאפאן גז

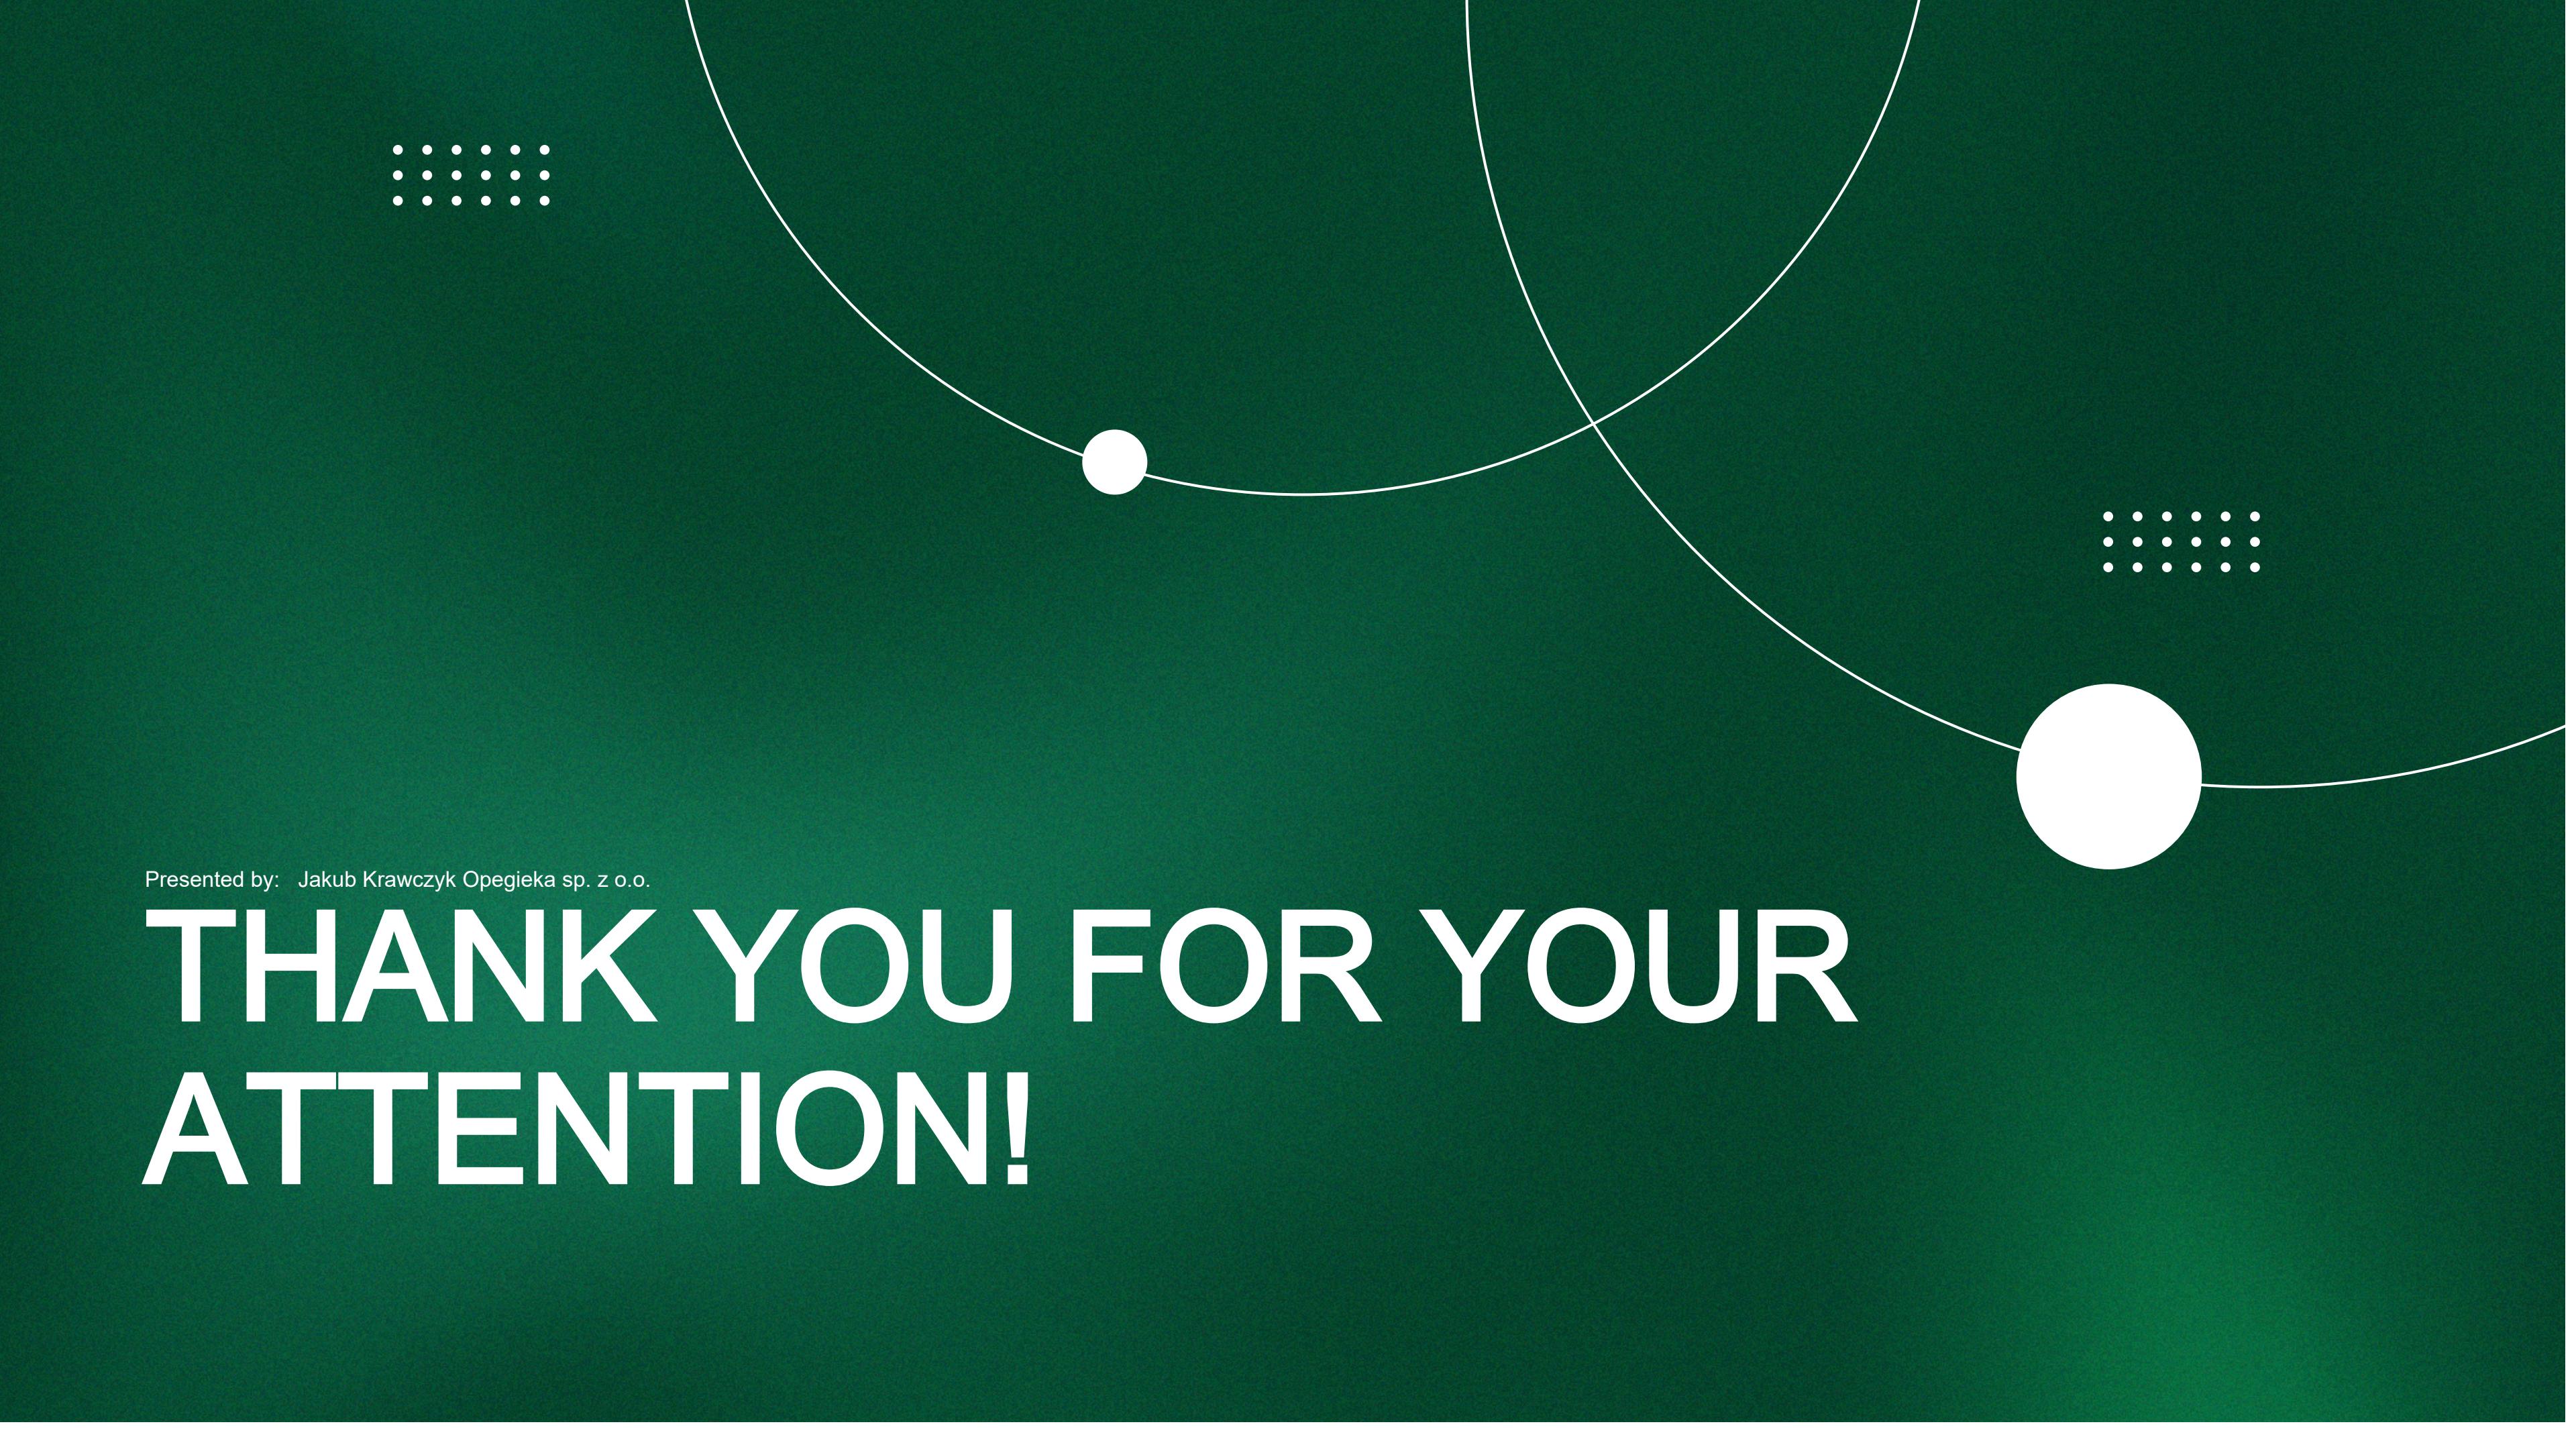
פשט קשוט דלא לא לרשף שחת צ

וליש פאנט נטעצט אונטראן הא

כשט פלאן | אנטראן טמונת פל ז א

בפטה וו וטאש ליכטנשטיין





Presented by: Jakub Krawczyk Opegieka sp. z o.o.

**THANK YOU FOR YOUR
ATTENTION!**