

# CONSTRUCCIÓN DE UN ABORDAJE BASADO EN DATOS PARA UNA ATENCIÓN MÁS EFICAZ DE RECLAMOS POR FALLAS DEL SERVICIO ELÉCTRICO

**Carla Rosetti**

En ocasiones la máxima de “divide y reinarás” también funciona en el campo de los problemas de aprendizaje automático. En particular, ante escenarios que se presentan muy complejos, desmenuzar el problema en partes puede ser una buena estrategia para llegar a modelos más ajustados y más manejables.

Un área crítica en las empresas distribuidoras de Energía Eléctrica es la **atención a reclamos** por interrupciones en el servicio. Del gran volumen de llamados que se reciben en esta área clave, gran parte están fuera de la órbita de responsabilidad de la Distribuidora. Identificar estos reclamos improcedentes, y derivarlos a quien corresponda, supondría un gran ahorro de recursos que podrían reducir el coste de la operación y mejorar drásticamente la velocidad y calidad en la atención a los reclamos que sí son responsabilidad de la Distribuidora.

Junto a la distribuidora Light delineamos el objetivo de desarrollar una solución basada en aprendizaje automático que detecte tempranamente los llamados improcedentes y mejore la utilización de los recursos de la distribuidora.

Al momento de iniciar este proyecto contábamos con información muy limitada sobre los reclamos: los llamados realizados por el usuario, la localización de la incidencia y los desplazamientos de equipos para tratarla. Esta información resultó insuficiente para determinar automáticamente si una incidencia era improcedente o si podía resolverse sin desplazamiento de un equipo en el terreno. Por eso nos propusimos obtener e integrar información complementaria que nos permitiera caracterizar de forma más adecuada los reclamos:

- Información histórica sobre el servicio eléctrico en el domicilio (consumo, duración y frecuencia de cortes de energía)
- Información meteorológica de la hora previa al reclamo.
- Información sobre la red eléctrica donde se encuentra la instalación.

También caracterizamos diferentes subgrupos de usuarios e incidencias para analizar cómo funcionaban las predicciones para cada uno de estos subgrupos, y así poder hacer ajustes específicos. Por ejemplo, en casos de usuarios que realizaron reclamos recurrentes, se enriqueció la información con datos de esas incidencias previas.

Por otro lado, mejoramos el objetivo de predicción en sí, tratando de obtener predicciones más adecuadas a los datos con los que contábamos. Efectivamente, en muchos casos resulta impredecible determinar si un reclamo es procedente o no. En cambio, se puede predecir de forma mucho más confiable si un reclamo va a requerir el desplazamiento de un equipo o si recomendamos alguna otra acción previa, rápida y de menor coste con posibilidades de cerrar la incidencia. Para eso caracterizamos la evolución de cada reclamo a través del tiempo, y proponemos de forma proactiva diferentes acciones lo antes posible.

De esta forma conseguimos mejorar considerablemente el rendimiento del modelo, incorporando información complementaria y caracterizando los casos más particulares.

# CRIANDO UMA ABORDAGEM ORIENTADA POR DADOS PARA UM TRATAMENTO MAIS EFICAZ DAS RECLAMAÇÕES DE FALTA DE ENERGIA

**Carla Rosetti**

Às vezes, a máxima “dividir para reinar” também funciona no campo dos problemas de aprendizado de máquina. Em particular, ao se deparar com cenários muito complexos, dividir o problema em partes pode ser uma boa estratégia para chegar a modelos mais rígidos e gerenciáveis.

Uma área crítica nas empresas de distribuição de eletricidade é o **tratamento de reclamações** sobre interrupções de serviço. Do grande volume de chamadas recebidas nessa área importante, uma grande proporção está fora da área de responsabilidade da empresa de distribuição. Identificar essas reclamações inadequadas e encaminhá-las para as partes apropriadas economizaria recursos que poderiam reduzir o custo da operação e melhoraria drasticamente a velocidade e a qualidade do tratamento das reclamações que são de responsabilidade da Distribuidora.

Juntamente com o distribuidor Light, delineamos o objetivo de desenvolver uma solução baseada em aprendizado de máquina que detectasse precocemente chamadas inadequadas e melhorasse a utilização dos recursos do distribuidor.

No início deste projeto, tínhamos informações muito limitadas sobre reclamações: as chamadas feitas pelo usuário, o local do incidente e as viagens da equipe para lidar com ele. Essas informações eram insuficientes para determinar automaticamente se um incidente era inadequado ou se poderia ser resolvido sem uma viagem da equipe ao campo. Por isso, nos propusemos a obter e integrar informações complementares que nos permitissem caracterizar melhor as reclamações:

- Informações históricas sobre o serviço de eletricidade na residência (consumo, duração e frequência das interrupções)

- Informações meteorológicas do período anterior à reclamação.
- Informações sobre a rede elétrica onde a instalação está localizada.

Também caracterizamos diferentes subgrupos de usuários e incidentes a fim de analisar como as previsões funcionavam para cada um desses subgrupos, de modo que ajustes específicos pudessem ser feitos. Por exemplo, nos casos de usuários que faziam reclamações recorrentes, enriquecemos as informações com dados desses incidentes anteriores.

Também aprimoramos o próprio objetivo da previsão, tentando obter previsões mais adequadas aos dados que tínhamos. De fato, em muitos casos, é imprevisível determinar se uma reclamação é válida ou não. Por outro lado, é possível prever de forma muito mais confiável se uma reclamação exigirá o deslocamento de uma equipe ou se recomendaremos alguma outra ação prévia, rápida e menos dispendiosa, com a possibilidade de encerrar o incidente. Para isso, caracterizamos a evolução de cada reclamação ao longo do tempo e propomos proativamente ações diferentes o mais rápido possível.

Dessa forma, conseguimos melhorar consideravelmente o desempenho do modelo, incorporando informações complementares e caracterizando os casos mais particulares.